

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

**KOMPARATIVNA ANALIZA ALATA ZA WEB
ANALITIKU**

Mentor:

Doc. dr. sc. Daniela Garbin Praničević

Student:

Kristina Rašetina,univ.bacc.oec

Split, ožujak, 2017.

Sadržaj:

1. UVOD	4
1.1. Problem i predmet istraživanja	4
1.2. Ciljevi istraživanja	6
1.3. Istraživačke hipoteze.....	7
1.4. Metode istraživanja.....	7
1.5. Doprinos istraživanja.....	10
1.6. Sadržaj diplomskog rada	11
2. WEB ANALITIKA.....	12
2.1. Općenito o web analitici	12
2.2. Povijest web analitike	16
2.3. Korištenje web analitike u poslovanju	19
2.3.1. Poslovni modeli na webu	20
2.3.2. Mjerenje uspješnosti web stranica	21
2.3.3. Taktičko korištenje web analitike	25
2.4. Prikupljanje podataka za web analitiku	28
2.4.1. Prikupljanje podataka web logovima.....	29
2.4.2. Prikupljanje podataka tagiranjem stranica	30
2.4.3. Problem privatnosti i zaštite korisnika u prikupljanju podataka.....	32
3. ALATI ZA WEB ANALITIKU	34
3.1. Općenito o alatima	34
3.1.1. Razvoj alata za WA	35
3.1.2. Kategorizacija alata.....	35
3.1.3. Funkcionalnosti alata za web analitiku	36
3.2. Tržište	38
3.3. Pregled odabranih alata.....	40
3.3.1. Google Analytics	41
3.3.2. Google Analytics 360	43
3.3.3. Piwik	43
3.3.4. IBM Digital Analytics (Coremetrics)	45
3.3.5. Webtrends Infinity	46
3.3.6. Mint.....	47
3.3.7. Mixpanel	48

3.3.8. KISSmetrics	50
3.3.9. Woopra.....	51
3.3.10. Clicky.....	52
3.3.11. GoingUp.....	53
3.3.12. Open Web Analytics	54
3.3.13. StatCounter.....	55
3.3.14. Adobe SiteCatalyst (Adobe Analytics)	56
3.3.15. Chartbeat	58
3.3.16. GoSquared.....	59
3.3.17. AT Internet – Analytics Suite	60
3.3.18. FoxMetrics	62
3.3.19. Adobe Digital Analytix.....	63
3.3.20. AWStats	63
4. KOMPARACIJA ALATA ZA WEB ANALITIKU	64
4.1. Višekriterijska analiza.....	64
4.1.1. AHP metoda.....	66
4.1.2. Kriteriji za evaluaciju alata za WA.....	69
4.2. Super Decisions	70
4.3. Provođenje AHP metode.....	71
4.4. Odabir alata za web analitiku.....	80
5. ZAKLJUČAK.....	83
LITERATURA:	86
POPIS SLIKA.....	91
POPIS TABLICA	92
POPIS GRAFIKONA	92
SAŽETAK	93
SUMMARY	94

1. UVOD

1.1. Problem i predmet istraživanja

Internet ubrzano raste i ima veliki utjecaj na mnoge sfere poslovanja. Tisuće kompanija posjeduju web stranice koje su postale integrirani dio poslovanja. Također, veliki broj kompanija uveo je brojne tehnologije koje su dostupne putem web-a u obliku online usluga. Pomoću informacija sa web-a, web programeri i dizajneri mogu poboljšati korisnička sučelja, alate za pretraživanje, postavke navigacije, online pomoć i sadržaj informacija, te na taj način povećati zadovoljstvo posjetitelja, odnosno kupaca stranice (Bothma & Fourie, 2007).

U poslovnom svijetu sve se češće koristi web analitika kako bi se pratilo korištenje web stranica. Prema službenoj definiciji web analitika obuhvaća mjerenje, prikupljanje, analizu i izvještavanje prikupljenih podataka sa interneta u cilju razumijevanja i optimiziranja web iskustva (Web Analytics Association, 2008).

Umjesto pasivnog odgovaranja na ono što se događa, tvrtke sve češće nastoje proaktivno iskoristiti ono što podaci otkrivaju, te se u skladu s tim usmjeravaju na postizanje strateški važnih ciljeva (Davenport *et al.*, 2005). Takav pristup zahtjeva ne samo veliku količinu podataka, već i sofisticirane mogućnosti analitičke obrade podataka. Upravo alati za analitiku pružaju takve mogućnosti. Alati za web analitiku prikupljaju podatke o klikovima korisnika, prate kretanje korisnika po stranici, te procesuiraju i prezentiraju podatke u obliku vrijednih informacija. Web analitika koristi se za razumijevanje online kupaca i njihovih ponašanja, osmišljavanje aktivnosti kojima će se utjecati na njih, te konačno za poticanje ponašanja korisnika za poslovanje i postizanje ciljeva organizacije (Nakatani i Chaung, 2011).

Aberdeen grupa identificirala je šest ključnih tehnologija i usluga koje bi svaki alat za web analitiku trebao imati. Prva dva su profili posjetitelja i profili ponude – kratki opisi karakteristika posjetitelja i web stranica, a preostala četiri čine procesi: snimanje podataka, transformacija, pohrana, te izvještavanje i akcija (Creese & Veytsel, 2000).

S obzirom da odabir alata za web analitiku ima dugoročne strateške implikacije, kompanije bi trebale odabrati alat u skladu sa vlastitim poslovnim modelom, na način da odluče koje su ključne karakteristike alata na koje se trebaju usredotočiti. Područje web analitike razvija se velikom brzinom, što uzrokuje povećanje broja i opsega dostupnih alata na tržištu. Brojnost alata za web analitiku koji se nude, kao i odluka o tome koje kriterije treba uzeti u razmatranje prilikom odabira alata predstavlja velik izazov za kompanije. Alati najčešće imaju velik broj funkcionalnosti, stoga za primjerice jednostavnu web stranicu koja samo pruža informacije, većina ovih funkcionalnosti nije potrebna. (Hausmann *et al.*, 2012). Uglavnom se javlja dvojba u odabiru između besplatnih i komercijalnih alata. Besplatni alati s jedne strane zahtijevaju minimalno ulaganje, ali obično pružaju manja poboljšanja u poslovanja. Komercijalni alati pak, traže mnogo veća finansijska ulaganja, ali istovremeno pružaju više mogućnosti kod kompleksnijih poslovnih zahtjeva koji potencijalno mogu donijeti velike profite.

Pregledom literature vezane za komparaciju alata za web analitiku, najčešće se nailazi na deskriptivnu komparaciju softvera prema njihovim funkcionalnostima na blogovima i internetskim portalima, uglavnom od strane stručnjaka iz prakse. Akademska zajednica fokusirala se uglavnom na općenite pojmove vezane za web analitiku i tehnologije koje se koriste, dok problematika komparacije i odabira softvera za web analitiku nije mnogo istražena. Stoga je u cilju da se u ovom radu proširi fokus akademskog istraživanja na analizu i usporedbu kvalitete funkcionalnosti različitih softvera.

Na temelju istražene problematike odabira alata za web analitiku, u radu će se predstaviti okvir za komparaciju alata za web analitiku temeljen na analitičkom hijerarhijskom procesu i korištenju softvera Super Decisions. Izvršit će se komparacija dvadeset softvera koji su popularni na tržištu, a o čijim se funkcionalnostima moglo pronaći dovoljno informacija. Za njihovu komparaciju koristit će se lista kvalitativnih kriterija koja je sintetizirana pregledom relevantne literature. Softveri za web analitiku koji će se uspoređivati su: Google Analytics, Google Analytics 360, Piwik, IBM Digital Analytics, Webtrends Infinity, Mint, Mixpanel, KISSmetrics, Woopra, Clicky, GoingUp, Open Web Analytics, StatCounter, Adobe SiteCatalyst, Chartbeat, GoSquared, AT Internet – Analytics Suite, FoxMetrics, Adobe Digital Analytix, te AWStats. Ovom komparativnom analizom softvera nastojat će se što objektivnije odabrati najbolji softver

za web analitiku na temelju kvalitete njihovih funkcionalnosti. U konačnom razmatranju predložit će se i odabir alata s obzirom na različite poslovne zahtjeve poduzeća, uzimajući u obzir sve prednosti i nedostatke alata.

1.2. Ciljevi istraživanja

Nakon što su određeni problem i predmet istraživanja, *cilj ovog istraživanja je utvrditi funkcionalnosti pojedinih alata, te odrediti koji je alat najkvalitetniji s obzirom na kriterije definirane od strane istraživača pregledom literature. Stoga će se u radu izvršiti komparacija dvadeset alata za web analitiku na temelju višekriterijske analize AHP metodom.*

Ostali ciljevi rada:

- utvrditi prednosti i nedostatke pojedinih alata
- dati prijedlog odabira alata za web analitiku ovisno o različitim poslovnim potrebama kompanija

S obzirom na različite funkcionalnosti koje nude razni alati za web analitiku, poduzeća se nalaze u dilemi koji alat odabrati, ovisno o podacima kojima raspolažu i informacijama koje su im potrebne u poslovanju, te je proces donošenja odluke vrlo kompleksan.

Svrha ovog rada je napraviti kvalitetan i opsežan pregled najpopularnijih alata za web analitiku, ukazati na njihove prednosti i nedostatke, napraviti listu važnih kriterija prilikom odabira softvera, te prema tome odabrati najkvalitetniji alat, kako bi se olakšao proces donošenja odluke o odabiru alata za web analitiku.

1.3. Istraživačke hipoteze

Hipoteza predstavlja svaku pretpostavku koja se želi ispitati putem određenog istraživanja. (Tkalcic-Verčič *et al.*, 2011).

S obzirom da je predmet ovog istraživanja utvrditi koji je najkvalitetniji alat za web analitiku komparacijom alata prema njihovim funkcionalnostima, postavlja se sljedeća hipoteza:

H₁:.....Postoje razlike u razini kvalitete funkcionalnosti alata za web analitiku.

Može se reći kako istraživačka hipoteza iskazuje predviđanje istraživača kojima se on vodi u svom istraživanju. Hipoteza će se dokazati na način da će se na temelju kriterija definiranih pregledom relevantne literature provesti evaluacija i komparacija dvadeset alata za web analitiku. Evaluacija i komparacija provest će se metodom višekriterijske analize, nakon čega će se odrediti koji alat je najkvalitetniji prema rezultatima istraživanja.

1.4. Metode istraživanja

Rad će se sastojati od teoretskog i empirijskog dijela. U teoretskom dijelu rada će se koristiti sljedeće metode istraživanja (Zelenika, 2000):

Metoda deskripcije je metoda koja se koristi u početnoj fazi znanstvenog istraživanja, a cilj joj je opisati predmete i pojave koji se istražuju bez znanstvenog tumačenja istih. Ova metoda će se u koristiti u radu za definiranje osnovnih pojmova kao što su web analitika, povijesni pregled web analitike, koristi od web analitike i sl.

Induktivno-deduktivna metoda je metoda koja se koristi za objašnjavanje ranije utvrđenih i otkrivanje novih spoznaja i zakonitosti, s ciljem dokazivanja postavljenih teza i provjeravanja hipoteza. Metoda započinje prikupljanjem činjenica pomoću zapažanja ili eksperimenata, na osnovu kojih se oblikuju hipoteze, a na temelju rezultata zapažanja ili eksperimenta donose se

zaključci. Indukcija i dedukcija trebaju se koristiti zajedno jer u protivnom njihovi rezultati nisu pouzdani.

Metoda analize koristi se za raščlanjivanje složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente. U radu će se koristiti kako bi se opisale funkcionalnosti svakog alata pojedinačno.

Metoda sinteze je postupak znanstvenog istraživanja i objašnjavanja stvarnosti putem sinteze jednostavnih sudova u složenije.

Metoda klasifikacije je sistematska i potpuna podjela općeg pojma na posebne, koje taj pojam obuhvaća. Predmet koji se klasificira mora biti jasno definiran, a klasifikacija se mora obaviti na temelju neke osobine koja je karakteristična za vrstu predmeta koji se proučava. U radu će se ova metoda koristiti za klasificiranje alata za web analitiku, prema tome da li se radi o besplatnom ili komercijalnom softveru.

Metoda kompilacije predstavlja neizostavni dio diplomskih radova. Temelji se na preuzimanju tuđih rezultata znanstveno istraživačkog rada, odnosno tuđih opažanja, stavova, zaključaka i spoznaja.

Metoda dokazivanja i opovrgavanja koristi se za potvrdu istinitosti ranije definiranih stavova. Prilikom dokazivanja traže se pretpostavke koje određenu hipotezu trebaju dokazati. Suprotna metoda je opovrgavanje, kada se teze odbacuju ili opovrgavaju. U radu će se koristiti kako bi se potvrdili ili opovrgnuli zaključci o korištenju određenih web alata s obzirom na poslovne zahtjeve poduzeća.

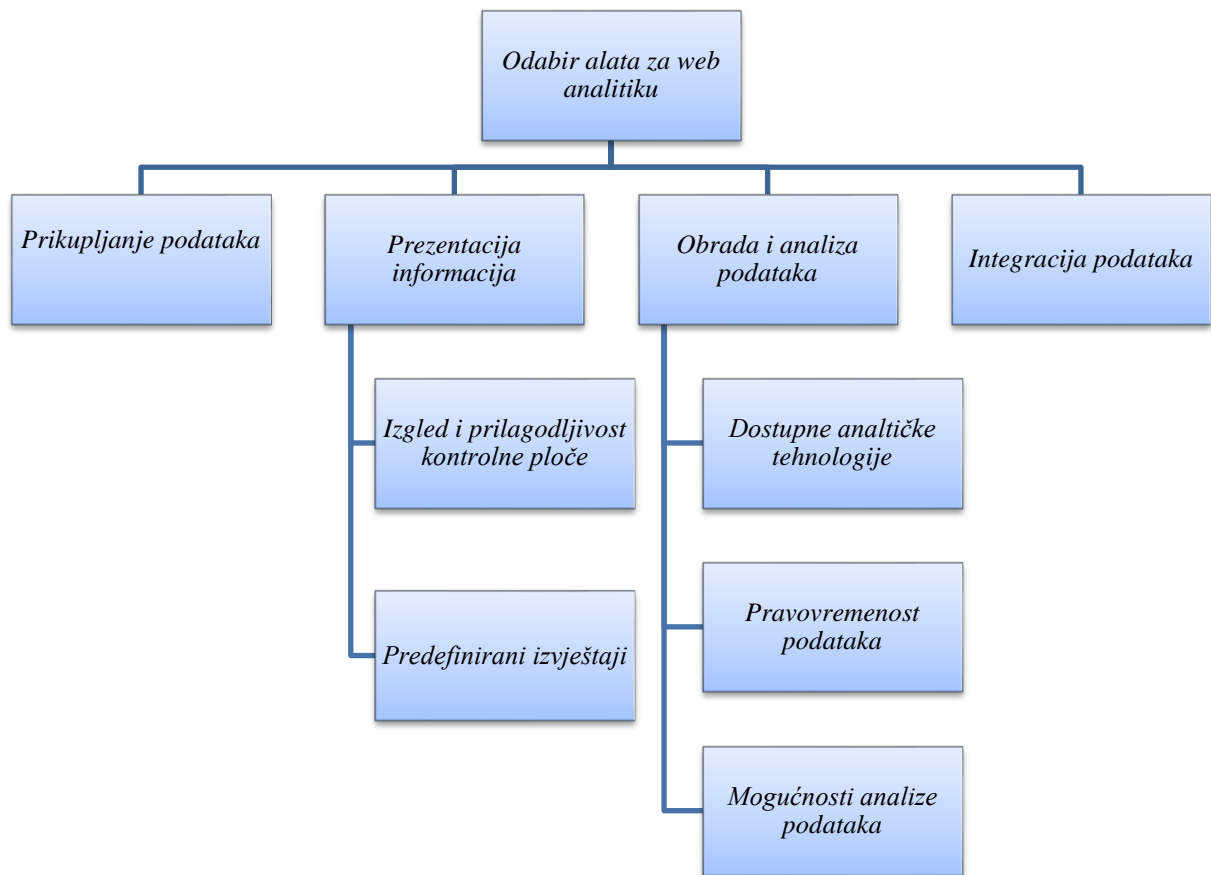
Komparativna metoda koristi se za uspoređivanje istih ili srodnih činjenica kako bi se utvrdile njihove sličnosti ili razlike. U radu će se koristiti za uspoređivanje alata za web analitiku.

U empirijskom dijelu rada u svrhu komparacije alata za web analitiku koristit će se višekriterijska analiza, odnosno AHP metoda.

Višekriterijska analiza je skup metoda koje omogućuju objedinjavanje nekoliko kriterija s ciljem odabira, sortiranja, rangiranja ili opisivanja određenih alternativa (Triantaphyllou 1998, u Klanac *et al.*, 2013).

AHP metoda ili **metoda analitičkog hijerarhijskog procesa** spada u najpoznatije i posljednjih godina najviše korištene metode za odlučivanje kada se proces odlučivanja, odnosno izbor neke od raspoloživih alternativa ili njihovo rangiranje, temelji na više atributa koji imaju različitu važnost i koji se izražavaju pomoću različitih skala. AHP metoda omogućava fleksibilnost procesa odlučivanja i pomaže donositeljima odluka da postave prioritete i donesu kvalitetnu odluku uzevši u obzir i kvalitativne i kvantitativne aspekte odluke (Saaty, 1991 navedeno u Begičević, 2008). U radu će se koristiti kako bi se napravilo rangiranje, odnosno odredila važnost pojedinog kriterija za usporedbu alata za web analitiku. AHP metoda će se provesti uz pomoć besplatnog softvera Super Decisions.

Sintezom nekoliko prethodnih istraživanja na temu komparacije alata za web analitiku (Natakani i Chuang, 2011, Creese & Veytsel, 2000, Bothma & Fourie, 2007) odabrani su kriteriji za evaluaciju i rangiranje alata, te je izrađena AHP hijerarhija kriterija, prikazana na grafikonu 1.



Grafikon 1: Kriteriji za evaluaciju alata za web analitiku

Izvor: Prikaz autora

1.5. Doprinos istraživanja

Doprinos ovog istraživanja je usporedba funkcionalnosti pojedinih alata, analiza njihovih prednosti i nedostataka, te odabir najkvalitetnijeg alata. Ovo istraživanje rezultirat će kreiranjem metode selekcije i okvira za usporedbu alata za web analitiku što doprinosi stručnjacima u praksi, kao i akademskoj zajednici. Rad će objediniti ocjenu alata prema najvažnijim kriterijima funkcionalnosti, sa pregledom njihovih prednosti i nedostataka vezano za cijenu i ostale kriterije. Stoga, rezultate istraživanja kompanije mogu koristiti kao metodološki okvir za odabir alata sukladno vlastitim poslovnim potrebama.

U akademskom pogledu, ovaj rad popunjava prazninu u području komparacije alata za web analitiku korištenjem AHP metode i softvera za komparaciju alata. U tom smislu, ovo istraživanje može pridonijeti interesu akademske zajednice za ovo područje i biti polazište za daljnja istraživanja ove problematike, kao i pomoć studentima ekonomskih fakulteta prilikom pisanja seminarskih, istraživačkih, završnih, te diplomskih radova.

1.6. Sadržaj diplomskog rada

Rad je koncipiran na način da je podijeljen u pet poglavlja, uključujući uvod i zaključak.

Prvo poglavlje je uvodni dio u kojem će se definirati problem i predmet istraživanja. Postavit će se istraživačke hipoteze i objasniti znanstvene metode koje će se koristiti u istraživanju. Također će se definirati ciljevi i svrha istraživanja, te doprinos rezultata istraživanja.

U drugom dijelu rada će se iznijeti opće definicije o web analitici, te opisati povijest razvoja web analitike. Zatim će se pojasniti zašto se web analitika koristi u poslovanju ovisno o različitim poslovnim potrebama, te će se pojasniti način prikupljanja podataka potrebnih za analitiku.

U trećem poglavlju započet će se sa općenitom analizom alata i tržišta alata za web analitiku. Navest će se svrha i svojstva alata, njihova klasifikacija, zatim karakteristike tržišta, ponuda alata na tržištu s obzirom na veličinu poduzeća, te informacije o tržišnim udjelima. Zatim će se u nastavku napraviti pregled svakog od dvadeset odabranih alata za web analitiku, navodeći njihove karakteristike, prednosti i nedostatke.

U četvrtom poglavlju će se provesti komparacija alata za web analitiku korištenjem AHP metode. Poglavlje započinje kratkim navođenjem karakteristika višekriterijske analize i detaljnijim opisom AHP metode i koraka u provođenju metode. Zatim će se prikazati osnovne karakteristike softvera Super Decisions. Na kraju poglavlja prikazat će se provođenje metode i rezultati, te odabir optimalnog alata.

U petom poglavlju, će se iznijeti zaključna razmatranja na temelju kojih će se prihvatiti ili odbaciti postavljene hipoteze. Na kraju diplomskog rada prikazat će se korištena literatura i popisi slika, grafova i tablica koje su korištene u radu.

2. WEB ANALITIKA

2.1. Općenito o web analitici

Web stranica organizacije obogaćuje imidž poslovanja i pruža izravne koristi u smislu elektroničke trgovine (Inge Geyskens, 2002 navedeno u Omidvar *et al.*, 2011) i neizravne koristi u smislu pružanja informacija, brendiranja i usluga (Lederer *et al.*, 2001 navedeno u Omidvar *et al.*, 2011). Partneri organizacije i klijenti često provode više vremena u interakciji sa web stranicama nego sa zaposlenicima organizacije (Creese & Veytsel, 2000). Stoga se može zaključiti kako upotrebljivost i funkcionalnost web stranice imaju bitan utjecaj na percepciju klijenta o organizaciji.

Mnoge organizacije danas imaju web stranice kojima nadopunjavaju svoje ostale aktivnosti, ali čini se da znatno manji dio njih uistinu zna koliko su njihove stranice uspješne (Phippen *et al.*, 2004). Loša funkcionalnost web stranice ima negativan utjecaj na ROI, te može naštetiti brendu. Problem može biti u lošem ciljanju marketinških kampanja, lošim kritikama proizvoda ili usluga na webu ili u preniskoj stopi konverzije. Upravo web analitika osigurava alate za otkrivanje ovakvih problema i omogućuje usporedbu efekata (Clifton, 2010).

Osim službene definicije web analitike (WAA, 2008) koja je navedena u uvodnom dijelu rada, brojni drugi autori pokušali su definirati web analitiku. Autori Creese & Veytsel (2000) navode da je web analitika praćenje i izvještavanje o korištenju web stranice kako bi poduzeća mogla bolje razumjeti kompleksne interakcije između aktivnosti posjetitelja i ponude web stranice, kao i korištenje tih informacija kako bi se optimizirala stranica u svrhu povećanja prodaje i lojalnosti klijenata. Sličnu definiciju daje i McFadden (2005) koji smatra da se web analitika odnosi na

prikupljanje, analizu i izvještavanje o korištenju web stranice od strane posjetitelja i kupaca te stranice. Također, autor navodi da ove informacije koriste oni koji su odgovorni za uspjeh web stranice kako bi bolje razumjeli efekte promjena koje uvode na stranice. Ova saznanja mogu se koristiti za optimiziranje web stranica kako bi one efektivnije ostvarivale ciljeve poslovanja.

Implementacijom web analitike može se dobiti uvid u veliki broj osnovnih informacija kao što su: dnevni broj posjetitelja na stranici, stope konverzije, najposjećenije stranice, prosječno vrijeme koje korisnici provedu na stranicama, geografska distribucija posjetitelja i slično. Pri naprednijim analizama moguće je doznati i složenije informacije kao što su: vrijednost posjetitelja i distribucija vrijednosti prema mjestu, vrijednost stranice, ponašanje novih posjetitelja u odnosu na postojeće ili informaciju koliko je u prosjeku posjeta i vremena potrebno da posjetitelj postane kupac. Sve te informacije mogu biti od velike koristi u procesu donošenja odluka koje se odnose na poboljšanje *online* strategije nabolje što je i svrha web analitike (Clifton, 2010). Navedena saznanja autora upućuju na to kako je važno razumjeti da web analitika nije sama sebi svrha, već služi prije svega za poboljšanje poslovanja i zadovoljstva korisnika web stranice.

Alati za web analitiku proizvode veliki broj informacija o korištenju web stranice. Ukoliko menadžeri izrađuju izvještaje s metrikama koje nisu usklađene sa strateškim ciljevima web stranice, korištenje alata postaje beskorisno (McFadden, 2005). Metrike su kvantitativne statističke mjere koje opisuju događaje i trendove na web stranicama (Kaushik, 2009). Stoga je važno naglasiti da oni koji koriste rezultate web analitike moraju imati odgovarajuća stručna znanja i vještine kako bi rezultati bili iskorišteni na najbolji mogući način. O tome govore i autori Waisberg & Kaushik (2009) koji tvrde da je web analitika znanost i umijeće. To je znanost o poboljšanju web stranica kako bi se povećala njihova profitabilnost, poboljšanjem korisničkog iskustva na stranici, u okviru koje se koristi statistika, tehnike rudarenja podataka i metodološki procesi. Analitičara podataka uspoređuju sa umjetnikom koji mora posjedovati visoku razinu kreativnosti, te odabrati prave podatke iz velike količine izvornih podataka kako bi dobio korisne informacije.

Web analitika nije samo tehnologija koja služi za izradu izvještaja, već je prije svega ciklički proces koji za osnovni cilj ima poboljšanje korisničkog iskustva, odnosno optimizaciju web stranice kako bi se povećala profitabilnost. Waisberg & Kaushik (2009) razvili su okvir za proces web analitike temeljen na najboljim praksama, koji sadrži sljedeće korake:

1. Definiranje ciljeva
2. Određivanje KPI-jeva
3. Prikupljanje podataka
4. Analiza podataka
5. Implementiranje promjena

Ključni čimbenik u određivanju ciljeva je razlog postojanja same stranice. Osim toga važno je zabilježiti što ključni stakeholderi vide kao primarni cilj web stranice. Stranice različitih namjena imaju različite ciljeve. Web trgovina ima za cilj što veću prodaju proizvoda. Stranica za korisničku podršku trebala bi pružati informacije korisniku s ciljem što većeg korisničkog zadovoljstva i što manjih troškova pozivnog centra. Portali imaju za cilj osigurati sadržaj različitih tema kako bi privukli što više korisnika, a time i povećali prodaju oglasnog prostora.


Na temelju poslovnih zahtjeva i ciljeva provodi se analiza mogućih metrika za uspješnost web stranice i odabiru se one koje najbolje odgovaraju definiranim ciljevima. Ove mjere koriste se i za izračun povrata ulaganja u web stanicu, koje treba imati pozitivan rezultat kako bi se ulaganje pokazalo isplativim. Postoje tri vrste metrika u web analitici – **brojevi, omjeri i ključni pokazatelji performansi** (Burby & Brown, 2007).

Svaki cilj trebao bi imati set jasno definiranih KPI-jeva kojima se mjeri napredak ostvarenja ciljeva kroz vrijeme (McFadden, 2005). KPI (ključni pokazatelj performansi) može biti u obliku broja ili omjera, a njihov odabir ovisi o poslovnoj strategiji i vrsti web stranice. Svaki KPI trebao bi biti povezan sa posljedičnom reakcijom u slučaju pada ili povećanja njegove vrijednosti. Generalno, kvalitetan KPI trebao bi posjedovati četiri atributa (Waisberg & Kaushik, 2009):

1. Jednostavnost – treba biti razumljiv za donositelje odluka iz svih odjela, a ne samo za web analitičare
2. Relevantnost – zbog jedinstvenosti svakog poslovanja i ciljeva organizacije važno formulirati odgovarajuće KPI –jeve
3. Pravovremenost – važna je kako bi donositelji odluka reagirali pravovremeno
4. Trenutna iskoristivost – važno je odmah razumijeti KPI kako bi se brzo dobio uvid u informaciju koju pruža

Prikupljanje podataka ključna je faza za daljnju analizu. Uključuje postavljanje odabranog alata za web analitiku koji će prikupljati relevantne podatke, koji se potom spremaju u bazu podataka. Podaci se najčešće prikupljaju pomoću dvije najraširenije metode: korištenjem **log** datoteka odnosno prikupljanje podataka od strane servera i **tagiranja** web stranica uz pomoć JavaScript koda. Detaljniji podaci o načinu prikupljanja podataka nalaze se u poglavlju 2.4.

U procesu analize podataka cilj je razumjeti ponašanje korisnika i otkriti korisne informacije za potporu odlučivanju iz podataka prikupljenih pomoću alata za web analitiku. Analiza podataka obuhvaća pregledavanje, pročišćavanje i transformaciju *clickstream*¹ podataka. Većina alata omogućuje moćnu analizu i generiranje kvalitetnih izvještaja. Poželjno je koristiti i ostale izvore podataka kako bi se dobio sveobuhvatan pogled na web stranicu i ponašanje korisnika. Ostali izvori mogu biti: online ankete, studije upotrebljivosti, analiza rada korisničke podrške i slično. U zadnjoj fazi vrši se implementacija promjena na temelju otkrivenih saznanja iz podataka. Ključno je da se promjene izvode postepeno, kako bi se smanjio rizik i otkrilo koje promjene donose poboljšanja, a koje nemaju učinka.




Slika 1: Proces web analitike

Izvor: Waisberg, D. & Kaushik, A. (2009). Web Analytics 2.0: Empowering Customer Centricity

¹ engl. *clickstream*. Podaci prikupljeni o aktivnostima korisnika na Web mjestu

2.2. Povijest web analitike

Nekoliko godina nakon stvaranja world wide web-a može se govoriti o počecima web analitike. Godine 1993. u log datoteke počeli su se bilježiti podaci svaki put kada bi posjetitelj zatražio HTML element. Elementi su uključivali tekst, sliku, zvuk ili video. Log datoteke su osim podatka da je netko posjetio stranicu, zabilježavale i druge podatke kao što su: ime datoteke, vrijeme, web stranicu koja traži zahtjev, IP adresu, identifikator pretraživača, operacijski sustav, itd. S obzirom da su log datoteke postajale sve veće, počeli su se pisati programi koji su raščlanjivali log datoteke i prikazivali osnovne metrike, što se smatra službenim nastankom web analitike. Stephen Turner 1995. godine kreirao je **Analog** - jedan od prvih programa za analizu log datoteka koji je bio lako dostupan na webu (Kaushik, 2007). Konačno, to je omogućilo da web analitiku mogu koristiti i marketinški stručnjaci, a ne samo tehnološki timovi.



Slika 2: Primjer izvještaja iz Analoga, verzija beta 0.9

Izvor: Kaushik, A. (2007). Web Analytics: An Hour a Day

U sljedećoj godini došlo je do pojave vrlo popularnih brojača na web stranicama, a prvi takav široko korišteni servis bio je Web Counter. Komercijalna web analitika pojavila se nekoliko godina kasnije predvođena tvrtkom Web Trends koja je poboljšala standardni parser log datoteka, te dodala tablice i grafove (Kaushik, 2007). Do 2000. godine popularnost web analitike rasla je eksponencijalno, a jedan od pokazatelja je porast industrije web analitike u 1999-oj godini za čak 200%. Neki od ključnih dobavljača na tržištu bili su tvrtke NetGenesis, Accrue,

WebTrends, Coremetrics. Pojavom drugih elemenata na web stranicama osim teksta i slika, dobavljači i korisnici web analitike počeli su uočavati probleme korištenja web server log datoteka. Problemi su bili vezani za identificiranje jedinstvenih posjetitelja (Unique Visitors), crawlere tražilica čiji bi se ulasci uključivali u rezultate metrike i page caching od strane pružatelja internetskih usluga.

JavaScript tagiranje postaje novi standard prikupljanja podataka koji se zadržao kao najraširenija metoda prikupljanja podataka sve do danas. JavaScript log datoteke bile su jednostavnije za održavanje od web server log datoteka; nekoliko redaka JavaScript koda dodaje se na svaku stranicu, a kada se stranica učita kod šalje podatke na server za prikupljanje podataka. (Kaushik, 2007)

Pucanjem internetskog balona, tržište web analitike doživljava velike promjene. U 2001. godini broj dobavljača smanjuje se za pola. Nakon ovih događaja četiri najveća dobavljača na tržištu su: Coremetrics, Omniture, Websidestory i Web Trends. Tržište srednja veličine predstavljaju dobavljači Unica, IndexTools i ClickTracks, a javlja se i nekoliko besplatnih alata kao što su AWStats, Webalizer i StatCounter (Kauskih, 2007). S obzirom da web analitika postaje ključni alat za web optimizaciju 2004. godine osniva se Web Analytics Association (WAA), koja se danas naziva Digital Analytics Association (DAA).

Tvrtka Google 2005. godine kupuje Urchin, a 2006. lansira ga u obliku besplatnog alata pod nazivom Google Analytics. Ovaj alat vrlo brzo postaje najkorišteniji alat za web analitiku zbog svoje kvalitete i dostupnosti. Nakon toga dolazi do pojave analitike ugrađene u web stranice koja omogućuje vlasnicima da vide što posjetitelji rade, unutar web stranice. Inovacije u web analitici nastavljaju se u smjeru novih i jednostavnijih načina vizualizacije kompleksnih setova podataka (primjerice toplinske mape), te app analitike kojoj je cilj optimizacija pretraživanja weba za aplikacije.

Unatoč pohranjivanju mnogo terabajta clickstream podataka i velikih investicija u alate za web analitiku, mali broj kompanija razumije kako efektivno koristiti podatke (Sen *et al.*, 2006). Potaknut time autor Kaushik 2007. godine predstavlja novu paradigmu u svijetu web analitike –


web analitiku 2.0. To je koncept u kojem se zalaže za napuštanje tradicionalne web analitike koja analizu vrši samo na temelju kvantitativnih metrika i odgovara na pitanje „što se dogodilo?“.

Web analitika 2.0. je analiza kvalitativnih i kvantitativnih podataka vlastite i konkurentskih web stranica, radi provođenja kontinuiranog poboljšanja online iskustva kupaca i potencijalnih kupaca, što dovodi do ostvarenja željenih rezultata organizacije (Kaushik, 2009). Dok tradicionalni pristup web analitici stavlja naglasak na prikupljanje što veće količine clickstream podataka, ideja web analitike 2.0. je uključivanje različitih tipova podataka. Radi se o pet izvora podataka koji bi se trebali uzeti u obzir u cilju razumijevanju ponašanja kupaca i donošenju optimalnih odluka.

Na **prvoj razini** analiziraju se clickstream podaci prikupljeni pomoću alata za web analitiku. Oni predstavljaju osnovne podatke koji daju odgovore na pitanja što se događa na web stranici, primjerice informacije o posjetama, posjetiteljima, vremenu provedenom na stranici i slično. Na **drugoј razini** mjeri se broj konverzija na web stranici u odnosu na različite poslovne ciljeve web stranica. Osim toga analitičari trebaju prepoznati razloge zbog kojih korisnici i organizacije posjećuju, odnosno posjeduju web stranice. Rezultati takvih različitih ciljeva trebaju biti izmjereni kako bi se dobila potpuna slika o sveukupnom ispunjenju cilja web stranice. **Treća razina** odnosi se na eksperimentiranje i testiranje, odnosno smišljanje različitih poslovnih rješenja i traženje povratnih informacija od posjetitelja stranice. Na taj način korisnici, odnosno potencijalni kupci biraju ono što je za njih najprihvatljivije, a organizacija uči od korisnika. Najčešće se radi o A/B testiranju (odabir između dvije – A i B opcije) stranice, odnosno teksta, grafike, oglasa i ostalih elemenata, ali primjerice i testiranju cjenovnih taktika.

Na **četvrtoj razini** analiziraju se mišljenja kupaca, najčešće korištenjem online anketa. Analiza clickstream podataka nije dovoljna kako bi se donijeli zaključci o ponašanju korisnika i zadovoljstvu iskustvom na web stranici, s obzirom da takva analiza može dati samo izvještaje onoga što je zabilježeno. Primjerice, na temelju clickstream podataka ne može se pouzdano doznati koji je najpopularniji sadržaj na web stranici jer nije poznato da li su korisnici slučajno ili namjerno otvorili taj sadržaj. Na pitanje zašto, odgovor može dati samo glas kupaca (Kaushik,

2010). Konačno, na **petoj razini** potrebno je analizirati podatke o konkurenciji, kojih na internetu ima mnogo i dostupni su besplatno. Podaci o radu i uspješnosti stranice vrlo su vrijedni, no kada ih se stavi u kontekst okruženja i uspoređi sa rezultatima konkurencije, ti podaci postaju bogatstvo.



Slika 3: Usporedba grafičkog prikaza paradigmi Web Analitika 1.0. i Web analitika 2.0.

Izvor: Kaushik, A. (2009). Web Analytics 2.0: The Art of Online Accountability and Science of Customer Centricity

2.3. Korištenje web analitike u poslovanju

Web je jedini komunikacijski kanal koji omogućuje praćenje i analiziranje gotovo svega što kupci rade u interakciji s određenom tvrtkom. Sve aktivnosti na web stranici događaju se u realnom vremenu što omogućuje precizno i neposredno prikupljanje, analizu podataka i odgovor u kratkom vremenskom roku (Inan, 2006). Web analitika velikim tvrtkama omogućava: prognožiranje prometa na web stranicama za planiranje budućeg rasta, generiranje boljih ponuda kroz segmentaciju posjetitelja, mjerenje utjecaja različitih inicijativa na web stranici (npr. redizajn), pravilno investiranje u online marketinške kampanje, identificiranje partnera koje bi

valjalo zadržati ili ih se riješiti, te smanjenje troškova održavanja stranice uklanjanjem dijelova koji su slabo posjećeni. (Creese & Veytsel, 2000).

Unatoč navedenim mogućnostima koje pruža web analitika, kompanijama često nedostaje homogena organizacijska web strategija. Izazov leži u pronalasku adekvatnog načina mjerenja uspješnosti web stranice. Prije svega potrebno je identificirati svrhu postojanja web stranice i odgovarajuće zahtjeve za web analitikom, te odrediti što je potrebno mjeriti i zašto. Tek kada se odgovori na ova pitanja, može se odabrati odgovarajući alat za web analitiku (Hausmann, 2012). Ovisno o osnovnom cilju postojanja stranice, mogu se definirati različiti poslovni modeli na webu koji imaju različitu svrhu i ciljeve korištenja web analitike.

2.3.1. Poslovni modeli na webu

Poslovni modeli predstavljaju metodu vođenja poslovanja prema kojoj tvrtka može opstati, odnosno generirati profit. Tvrtke mogu imati jedan poslovni model ili kombinirati nekoliko različitih modela kao dio jedinstvene strategije web poslovanja. Osnovni poslovni modeli na webu su (Rappa, 2010):

1. **Brokerski model** – model poslovanja koji spaja kupce i prodavatelje i olakšava transakcije među njima, te za to uzima određenu proviziju. Primjeri su: eBay, PayPal, CashDirect.
2. **Oglašivački model** – model u kojem web stranica, najčešće besplatno, nudi sadržaj i usluge (kao što su e-mail, blogovi i sl.) u kombinaciji sa reklamnim porukama. Banner oglasi su glavni ili ponekad jedini izvor prihoda za oglašivača. Primjeri su: Yahoo!, Google, itd.
3. **Model informacijskih posrednika** – model kojem je cilj prikupljanje i distribucija informacija za pomoć kupcima i/ili prodavateljima kako bi razumjeli određeno tržište.
4. **Trgovački model** – obuhvaća trgovce na veliko i na malo. Primjeri su: amazon.com, Apple iTunes Store i sl.

5. **Proizvođački model** – zove se i direktni model u kojem proizvođač dolazi do kupaca bez posrednika. Temelji se na efikasnosti i boljem razumijevanju kupčevih preferencija. Primjer je Dell Computers.
6. **Suradnički model** – popularan model u kojem suradnici usmjeravaju korisnike svojih web stranica prema trgovcu, te tako ostvaruju proviziju. Primjer je Amazon.
7. **Model virtualnih zajednica** – model koji je baziran na korisničkoj lojalnosti. Prihodi se generiraju na temelju sekundarnih proizvoda i usluga, donacijama ili pretplatama na premium usluge.
8. **Pretplatnički model** – model u kojem se korisnicima naplaćuje dnevna, mjesečna ili godišnja naknada kao pretplata na uslugu. Najčešće se kombinira besplatni i plaćeni sadržaj. Primjeri su Netflix, AOL...
9. **Model pomoćnih usluga** - model koji se temelji pristupu „na zahtjev“ ili „plaćanje po korištenju“. Glavna razlika u odnosu na pretplatnički model je što korisnici plaćaju isključivo one usluge koje koriste.

2.3.2. Mjerenje uspješnosti web stranica

Vrlo je teško odrediti koji elementi web stranice rade dobro, a što treba poboljšati, bez prikladnog i objektivnog načina mjerenja, analize i izvještavanja o korisničkom ponašanju (McFadden, 2005). Dugo vremena osnovne metrike smatrale su se temeljom web analitike i osnovnim pokazateljima uspješnosti web stranica. WAA (2008.) definirala je četiri temeljne metrike:

- **Posjeti (Visits)** – brojčana metrika koja mjeri broj interakcija posjetitelja sa web stranicom koja se sastoji od jednog ili više zahtjeva za web stranicom. Vrijeme koje posjetitelj provede na stranici naziva se *sesija*. Alati za web analitiku mjere posjet odnosno sesiju od prvog do zadnjeg zahtjeva posjetitelja. Ukoliko je korisnik neaktivan na otvorenoj stranici više od 29 minuta, ta se sesija prekida. Gotovo svi alati izvještavaju i o navigacijskom putu pojedinog posjeta.

- **Jedinstveni posjetitelji (Unique Visitors)** – brojčana metrika kojom se mjeri broj ljudi koji su posjetili stranicu barem jednom u određenom vremenskom razdoblju mjerenja. Svaki pojedinac broji se samo jednom za određeno vremensko razdoblje, bez obzira koliko je puta posjetio stranicu. Upravo tu se pojavljuje osnovni problem, a to je kako odrediti jedinstvenost posjetitelja. Dominantna metoda identifikacije je putem kolačića koji pohranjuju i vraćaju jedinstvenu ID vrijednost. Nedostaci ove metode predstavljeni su u 3 poglavlju rada.
- **Pregled stranice (Page View)** – metrika koja se izražava u obliku broja a pokazuje koliko je puta stranica pregledana, neovisno o broju slika ili objekata koji čine tu stranicu. Metrika Pregledi stranica po posjeti (Page view per visit) daje podatke o broju pregledanih stranica od strane posjetitelja za vrijeme trajanja posjeta web lokaciji.
- **Događaji (Events)** – metrike u obliku broja ili dimenzija koje broje svaku zabilježenu akciju kojoj je određen datum i vrijeme koje dodjeljuje server ili pretraživač. Događaji mogu biti: prikaz oglasa na stranici, početak i završetak transakcije, pokretanje multimedije, itd.

Tijekom vremena, tvrtke i menadžeri shvatili su da jednostavnost i dvoznačnost osnovnih metrika mogu dovesti do krivih zaključaka. Stoga se pojavila potreba za korištenjem novih metrika koje će biti više usmjerene prema kupcima kao ključnim čimbenikom uspjeha web stranice.

Metrike za opisivanje posjeta opisuju ponašanje posjetitelja tijekom posjeta web stranici, a analizom ovih metrika može se poboljšati korisnička interakcija sa stranicom. *Ulazna stranica (Entry Page)* je web stranica kojom posjetitelj započinje posjet web lokaciji. Obično se prikazuje lista sa URL-ova ili naslovima stranica, te se pokazuju najbolje ulazne stranice. *Ciljna stranica (Landing Page)* predstavlja stranicu koja identificira početak posjeta korisnika koje je rezultat određene marketinške aktivnosti. *Izlazna stranica (Exit Page)* je metrika koja označava zadnju stranicu kojoj je korisnik pristupio tijekom posjeta, te označava kraj posjete/sesije.

Dužina posjeta (Visit Duration) je brojčana metrika kojom se mjeri dužina sesije, a mjeri se na način da se od vremena zadnje aktivnosti u sesiji oduzme vrijeme prve aktivnosti u sesiji. Ovo je

popularna i korisna metrika jer daje informacije o angažiranosti posjetitelja (Web Analytics Association, 2008). Ukoliko je posjetitelj napustio web lokaciju nakon samo jedne pregledane stranice, ne može se znati koliko je zapravo posjetitelj vremena proveo pregledavajući stranicu, a alat za web analitiku će u tom slučaju najčešće zabilježiti da je vrijeme na web sjedištu 0 sekunda. Stoga, treba biti vrlo oprezan pri interpretaciji rezultata ove metrike, a pri izračunu prosječnog vremena koje korisnik provede na web stranici potrebno je isključiti podatke za sesije koje su obuhvaćale samo jednu web stranicu (Kaushik, 2007).

Izvor prometa (Referrer) je metrika koja pokazuje odakle dolazi promet na web stranicu. Stranica izvora prometa pokazuje stranicu na kojoj je posjetitelj došao prije nego je pregledao trenutnu stranicu. S obzirom na tip moguće je razlikovati (Web Analytics Association, 2008):

- Interni izvor prometa – izvor prometa je stranica s iste web lokacije
- Eksterni izvor prometa – izvor prometa je URL adresa izvan web lokacije
- Tražilice kao izvor prometa – mogu biti interne tražilice na web stranici, ali najčešće se radi o tražilicama poput Google-a, Yahoo-a i sl.
- Direktan promet – kada posjetitelj dolazi na stranicu direktnim unosom URL adrese u preglednik ili koristeći bookmark

Broj klikova na link (Click-through) je metrika kojom se mjeri koliko puta su posjetitelji kliknuli na poveznicu. Broj klikova može se podijeliti i sa brojem prikaza te poveznice. Ove dvije metrike korisne su za razumijevanje korisničke navigacije po web stranici. (Web Analytics Association, 2008).

Metrike za opisivanje posjetitelja omogućavaju segmentaciju posjetitelja čime se može poboljšati korisničko zadovoljstvo i iskustvo na web stranici. *Novi posjetitelj (New Visitor)* je brojčana metrika kojom se mjeri broj jedinstvenih posjetitelja koji su prvi put posjetili stranicu tijekom perioda izvještavanja. *Returning visitor* je metrika koja označava jedinstvenog posjetitelja koji je web stranicu posjetio u periodu mjerenja, ali je ujedno posjetio stranicu i prije tog perioda. *Repeat visitor* brojčana je metrika koja mjeri broj jedinstvenih posjetitelja koji su posjetili stranicu dva ili više puta tijekom perioda izvještavanja. *Broj posjeta po posjetitelju*

(*Visits per Visitor*) je metrika koja stavlja u omjer broj posjeta i broj jedinstvenih posjetitelja tijekom perioda izvještavanja (Web Analytics Association, 2008).

Metrike za opisivanje angažmana posjetitelja opisuju ponašanje posjetitelja na web stranici, odnosno njihovu interakciju sa stranicom. *Udio napuštanja web stranice u ukupnom broju prikaza stranice (Page Exit Ratio)* je metrika koja se računa kao omjer broja napuštanja neke stranice i ukupnog broja pregleda te stranice. *Stopa odustajanja (Bounce Rate)* stavlja u omjer posjete koji uključuju samo jedan prikaz stranice i broj ulaznih stranica. Ukoliko se stopa odustajanja računa za pojedinačnu stranicu, stavlja se u omjer broj posjeta te stranice i broj puta koliko je ta stranica bila ulazna stranica (Web Analytics Association, 2008).

Konverzijske metrike zabilježavaju posebne aktivnosti na stranici koje imaju određenu poslovnu vrijednost, kao što je npr. kupnja. *Konverzija (Conversion)* je metrika koja pokazuje koliko puta je postignut željeni rezultat, a definira se ovisno o poslovnim ciljevima različitih tipova web stranice. *Stopa konverzije (Conversion Rate)* je metrika koja predstavlja omjer konverzije i druge relevantne metrike. Brojnik i nazivnik moraju se slagati u jedinicama mjerenja, kao i u područjima mjerenja, stoga ako je primjerice konverzija „broj posjeta u kojima je izvršena kupnja“, onda bi u nazivniku trebao biti ukupan broj posjeta stranice (Web Analytics Association, 2008).

Metrike koje se koriste u poslovanju najčešće reflektiraju prošla ponašanja, te zbog toga imaju ograničenu mogućnost korištenja za poboljšanje performansi poduzeća (Becker, 2005 navedeno u McFadden, 2005). Drugi problem je što se prikupljaju velike količine podataka, te je ponekad teško odrediti koji su podaci važni za poslovanje, a koji su manje bitni. Kako bi se izvukle maksimalne koristi iz masivnih setova podataka koji se prikupljaju, potrebno je strateški odabrati osnovne metrike u vezi sa KPI-jevima. Primjerice, ako se prikupljaju različite web metrike vezane za posjetitelje kao što su broj posjeta, broj posjetitelja, te dužina posjeta, mogu se razviti KPI-jevi, kojima će se kreirati svestrani analitički model koji mjeri nekoliko metrika koje se stavljaju u omjer radi definiranja trendova posjetitelja (Jansen, 2009).

KPI-jevi omogućuju prevođenje kompleksnih mjera u jednostavne indikatore na temelju kojih donositelji odluka mogu reagirati vrlo brzo (Jansen, 2009), što ih čini strateškim poslovnim čimbenikom više nego IT alatom. Kada se analiziraju KPI-jevi važno je uzeti u obzir nekoliko činjenica (Clifton, 2010):

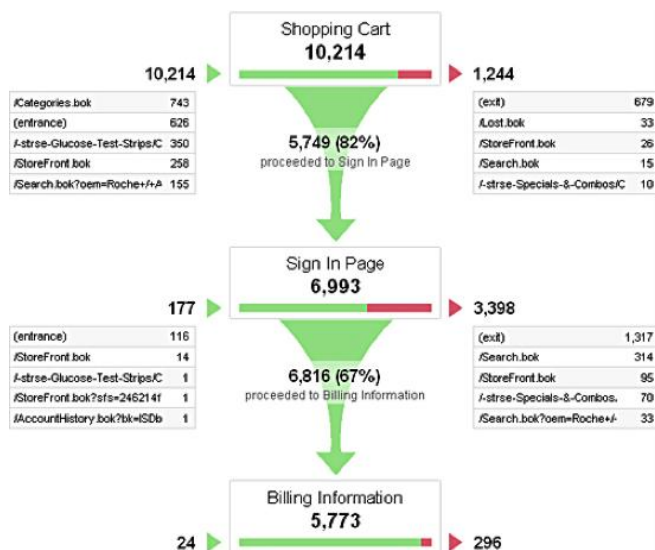
- Najčešće se radi o omjeru, postotku ili prosjeku a ne cijelom broju, te se na taj način omogućuje prezentiranje podataka u kontekstu
- Mora biti vezan za određeni vremenski period zbog brzine i učestalosti promjena u poslovanju
- Okidač je ključnih poslovnih poteza, što znači da KPI-jeve treba staviti u kontekst poslovanja te na temelju toga donositi odluke

2.3.3. Taktičko korištenje web analitike

Taktičko korištenje web analitike odnosi se na korištenje metoda koje omogućuju lakše razumijevanje web stranica i načina njihove optimizacije. Najvažnije metode su (McFadden, 2005):

- **Segmentacija i klasteriranje posjetitelja** – segmentacijom web stranica važni posjetitelji se smještaju u grupe prema sličnim obilježjima. Ovom metodom može se otkriti koji posjetitelji kupuju, koji samo pretražuju stranicu, koji najdulje ostaju ili se najčešće vraćaju, odakle su došli i prema razna druga obilježja. Osim po karakteristikama ponašanja na stranici, posjetitelji se mogu segmentirati i prema geografskoj lokaciji, spolu, godinama itd. Na višem nivou mogu se razviti i jedinstveni klasteri posjetitelj koji su primjerice slični po interesu, pretraživanju i kupovnim navikama (Lenzen, 2004). Ove metode koriste se prije svega kako bi se efektivnije koristile marketinške aktivnosti poput ponude proizvoda i usluga ili prikazivanja oglasa različitim skupinama posjetitelja.
- **Funnel analiza** – svi vodeći alati za web analitiku nude ovu analizu koja omogućava da korisnik postavi ulaznu stranicu koju želi analizirati i odredi međukorake koji vode do

konačne stranice ili događaja. Kao rezultat metode dobije se izvještaj sa grafičkim prikazom postotka ljudi koji su odustali na svakom pojedinom koraku. Ova metoda vrlo je korisna za online trgovine u praćenju konverzije posjetitelja, ali i za ostale vrste stranica kako bi se analizirali događaji na stranici koji donose poslovnu vrijednost.



Slika 4: Primjer funnel analize u alatu Google Analytics

Izvor: <http://online-behavior.com/analytics/funnel-analysis>

- **A/B testiranje** – koristi se najčešće za testiranje u marketingu, ali i za testiranje izoliranog dijela sadržaja na web stranicama kako bi se ispitalo koja od dviju verzija ima bolje rezultate. Testiranjem blagih varijacija moguće je odrediti koje male razlike čine najveću razliku, na način da se varijacije nasumično prezentiraju posjetiteljima i mjere se rezultati. Moguće je testirati različite dijelove stranice: početnu stranicu, ciljnu stranicu, stranicu proizvoda, promotivne ponude, oglase.
- **Optimizacija pretrage na stranici** – ključna je za web stranice koje imaju online trgovinu, ali je važna i za stranice koje nude sadržaje, te za samouslužne stranice. Za svaku stranicu važno je da posjetitelji mogu naći proizvod ili informaciju koja ih zanima, jer u suprotnom rezultat može biti izgubljeni kupac. Web analitika može se koristiti za praćenje funkcionalnosti interne pretrage, te analizu kako promjene pretrage utječu na performanse stranice.

- **Optimizacija web stranice (SEO - Search Engine Optimization)** – koristi se za poboljšanje renkinga web stranice prilikom korisničkih pretraga na internetskim tražilicama. Povećanje prometa na osnovu internetskih tražilica može se provesti na dva načina. Prvi način je putem plaćenih rezultata pretraživanja gdje se stranice pojavljuju kao sponzorirani linkovi na vrhu pretraživanja. Drugi način je optimizacija stranice za pretraživanja kako bi se stranica pojavila što bliže vrhu u rezultatima pretraživanja. Optimizacija web stranice postiže se aktivnostima kao što su omogućavanje lakog indeksiranja stranice od strane robota iz tražilica, čistoćom URL strukture, korištenjem pravih ključnih riječi, itd (Kaushik, 2009). Alati za web analitiku omogućuju upravljanje i mjerenje uspjeha optimizacije.



Slika 5: Primjer Google Analytics izvještaja o ukupnom prometu na stranici s prikazom udjela plaćenog i neplaćenog prometa

Izvor: Kaushik, A. (2009) Web Analytics 2.0: The Art of Online Accountability and Science of Customer Centricity.

- **Optimizacija početne i ciljnih stranica** - odnosi se na proces poboljšanja elemenata na početnoj i ciljnim stranicama kako bi se maksimizirao postotak posjetitelja koji ostvaruju željeni cilj stranice. Jedan od načina optimiziranja ciljne stranice jest da se ono što posjetitelji najčešće traže učini lako dostupnim i vidljivim na stranici.
- **Upravljanje online marketinškim performansama** - odnosi se na praćenje efektivnosti i uspješnosti online marketinških kampanja. Cilj je da pojedina kampanja generira više dobiti od troškova, a ona koja ne ispunjava ovaj kriterij treba se napustiti. Većina alata za

web analitiku ima kvalitetne alate za praćenje kampanja i izvora prometa. Vrlo koristan alat u ovom području su *modeli atribucije* (doprinosa) koji predstavljaju set pravila kojima se budžet za konverziju raspodjeljuje na različite kanale u procesu konverzije posjetitelja prema njihovoj važnosti.

2.4. Prikupljanje podataka za web analitiku

Prva metoda prikupljanja podataka koristila je log datoteke i neko vrijeme bila je jedina metoda koja se koristila. Nakon toga pojavljuje se metoda tagiranja stranica koja prikuplja podatke koristeći nevidljivi JavaScript kod. Ove dvije metode danas su najraširenije metode prikupljanja podataka, te će biti detaljnije objašnjene u ovom poglavlju. Osim navedenog, postoje i metode web beacons i packet sniffing koje se rijetko koriste u praksi.

Web beacons razvijeni su za mjerenje podataka o bannerima, e-mailovima i oglasima, te praćenje korisnika na više web lokacija (Hausmann, 2012). S obzirom na to da najčešće dolaze s third-party servera i uglavnom koriste third-party kolačiće imaju problem ugrožavanja privatnosti. Ne bi se trebali koristiti kao glavna metoda prikupljanja podataka, ali su pogodni za prikupljanje podataka sa različitih web lokacija. *Packet sniffing* je metoda koja se temelji na softveru ili hardveru – packet snifferima koji se postavljaju između korisnika i servera, te prikupljaju podatke u oba smjera. Samo nekolicina alata za web analitiku podržava ovu metodu, a cijene su visoke zbog dodatnih ulaganja u softver ili hardver. Dodatni nedostatak je što se ovom metodom prikupljaju i privatni podaci korisnika kao što su lozinke, adrese i slično.


Još jedan važan element u prikupljanju podataka za web analitiku su *kolačići (cookies)*. Oni se koriste u metodi tagiranja stranica u svrhu praćenja posjetitelja. Kolačići su male tekstualne poruke koje server prenosi internet pretraživaču za praćenje korisničke aktivnosti na određenoj web lokaciji, a pretraživač ih sprema na tvrdi disk posjetiteljeva računala. Kolačići koji se pohranjuju na računalo posjetitelja dok ne isteknu (imaju datum istjecanja) ili se ne izbrišu nazivaju se trajni kolačići. Postoje i privremeni kolačići koji traju samo tijekom korisnikova posjeta odnosno sesije, a potom se brišu (Beal, 2008). U web analitici, glavna svrha kolačića je

identificiranje korisnika, najčešće putem stvaranjem anonimnog ID-a posjetitelja. Mogu se koristiti za određivanje broja novih ili ponovnih posjetitelja, učestalost posjeta, te vrijeme između posjeta. Dvije su osnovne vrste kolačića: *first-party* i *third-party*. First-party kolačiće kreira domena web lokacije, a aktiviraju ih korisnici unošenjem URL-a u preglednik ili klikom na link. Third-party kolačići su najčešće povezani sa oglašavanjem ili umetnutim sadržajem od treće strane, tj. domene koju posjetitelj nije direktno zatražio. Ovi kolačići više ugrožavaju privatnost korisnika, s obzirom da omogućuju njegovo praćenje od drugih domena kojima je dopušteno vidjeti takve podatke (Clifton, 2010). Kolačići ne mogu naštetiti računalima, te se smatraju sigurnom i učinkovitom metodom prikupljanja podataka sve dok se poštuju pravila o privatnosti podataka. Glavni nedostatak je što posjetitelji mogu lako izbrisati kolačiće sa računala te ih se onda registrira kao nove korisnike pri ponovnom posjetu lokacije, a mogu i odbiti njihovo korištenje u internet pregledniku što onemogućuje prikupljanje podataka.

2.4.1. Prikupljanje podataka web logovima

Svaki put kada posjetitelj zatraži informacije sa web stranice, web serveri spremaju ovaj zahtjev u log datoteke (Waisberg & Kaushik, 2009). Najčešće informacije koje se prikupljaju su: IP adresa posjetitelja, korisničko ime posjetitelja (ukoliko je poznato), datum i vrijeme zahtjeva, metoda zahtjeva i resurs koji je zatražen (HTLM, GIF, JPG, itd.), kod statusa koji je poslan klijentu, te veličina poslanog objekta u bajtovima (Peterson, 2004). Prikupljeni podaci potom se mogu analizirati softverom za analizu web logova (Natakani, 2011). Proces prikupljanja podataka pomoću web logova sastoji se od četiri koraka (Waisberg & Kaushik, 2009):

1. Posjetitelj unosi URL adresu u preglednik
2. Zahtjev dolazi na neki od web servera
3. Server stvara unos u log datoteku
4. Stranica se isporučuje posjetitelju



Slika 6: Vizualizacija prikupljanja podataka pomoću log datoteka

Izvor: Waisberg, D. & Kaushik, A. (2009). Web Analytics 2.0: Empowering Customer Centricity


Ova tehnika temelji se na prikupljanju podataka na serverskoj strani (*server-side data collection*). U prošlosti je laka dostupnost log datoteka utjecala na brzo usvajanje ove metode za razumijevanje ponašanja korisnika stranice. Također, većina internet providera omogućuju besplatan dodatak za analizu logova u sklopu njihovih web hosting računa, ali takvi besplatni alati prejednostavni su za mjerenje korisničkog ponašanja (Clifton, 2010).

2.4.2. Prikupljanje podataka tagiranjem stranica

Ova tehnologija sastoji se od umetanja kratkih JavaScript kodova na svaku stranicu web lokacije. Svaki put kad posjetitelj otvori stranicu kod se aktivira, a podaci o posjetitelju i njegovim aktivnostima se spremaju u zasebnu datoteku (Waisberg & Kaushik, 2009). Tagovi stranica prikupljaju podatke putem internet preglednika posjetitelja i šalju informacije udaljenom servisu za prikupljanje podataka, a informacije potom pregledava analitičar. Ova metoda temelji se na prikupljanju podataka na strani klijenta (Clifton, 2010).

Proces prikupljanja podataka pomoću web logova sastoji se od pet koraka (Waisberg & Kaushik, 2009):

1. Posjetitelj unosi URL adresu u preglednik
2. Zahtjev dolazi na neki od web servera
3. Server isporučuje stranicu zajedno sa implementiranim JavaScript kodom korisniku
4. Kada se stranica učita izvršava JavaScript kod, koji prikuplja podatke o sesiji posjetitelja i kolačiće, te ih šalje natrag serveru koji prikuplja podatke
5. U nekim slučajevima nakon primitka prvog seta podataka, server šalje natrag dodatni kod pretraživaču kako bi postavio dodatne kolačiće ili prikupio još podataka



Slika 7: Vizualizacija prikupljanja podataka tagiranjem stranica

Izvor: Waisberg, D. & Kaushik, A. (2009). Web Analytics 2.0: Empowering Customer Centricity

Većina alata za web analitiku danas koristi tagiranje stranica kao metodu za prikupljanje podataka. Za vlasnike web stranica ova metoda je pogodna jer umanjuje troškove prikupljanja i obrade podataka, s obzirom da je za to odgovoran pružatelj usluge. Ipak, neke kompanije (kao što su ClickTracks i WebTrends) prodaju rješenja za prikupljanje podataka tagiranjem stranica kompanijama, što svakako ima prednosti zbog privatnosti, vlasništva i kontrole nad podacima

Osim smanjenih troškova metodu tagiranja stanica odlikuje jednostavnija implementacija s tehničkog aspekta, no ova metoda ipak nije uvijek dominantna nad ostalima zbog različitih potreba web lokacija. Najboljim rješenjem često se smatra hibridna metoda kao kombinacija tehnika log datoteka i tagiranja stranica, kojom se umanjuju pojedinačni nedostaci dviju metoda

(Clifton, 2010). Prikaz prednosti i nedostataka dviju osnovnih metoda prikupljanja podataka nalazi se u Tablici 1.

Tablica 1: Prednosti i nedostaci dviju osnovnih tehnika prikupljanja podataka

	Web logovi	Tagiranje stranica
Prednosti	<ul style="list-style-type: none"> ✓ Vlasništvo i kontrola nad podacima ✓ Pozdanost web servera u prikupljanju podataka ✓ Omogućuje analizu prošlih podataka ✓ Standardni format podataka objedinjenih na serveru kompanije ✓ Jedina metoda koja prati robote tražilice 	<ul style="list-style-type: none"> ✓ JavaScript kod se izvršava kada god je stranica učitana, stoga zabilježava i cachirane stranice ✓ Implementiranjem prilagođenih tagovamogu se prikupljati različiti podaci ✓ Dobavljači su odgovorni za postavljanje kolačića na računala posjetitelja ✓ Manji troškovi prikupljanja i obrade podataka
Nedostaci	<ul style="list-style-type: none"> ✓ Bilježe informacije o neuspjelim zahtjevima i robotima tražilicama što povećava promet stranice ✓ U promet se ne zabilježavaju cachirane stranice ✓ Ukoliko server ne postavi <i>kolačiće</i>, otežava se identificiranje posjetitelja 	<ul style="list-style-type: none"> ✓ Neki korisnici nemaju uključen JavaScript, što onemogućuje njihovo praćenje ✓ Otežano prikupljanje podataka o skidanju podataka sa stranice ✓ Stranicama koje već imaju mnogo JS koda, dodatni tagovi mogu stvoriti greške

Izvor: Prikaz autora

2.4.3. Problem privatnosti i zaštite korisnika u prikupljanju podataka

Problem privatnosti u web analitici javlja se zbog prikupljanja različitih vrsta informacija o korisnicima, a problem je složeniji time što su web lokacije najčešće dostupne za pregledavanje iz mnogih zemalja diljem svijeta koje imaju različite zakone i regulacije o zaštiti privatnosti na webu (Hausmann, 2012). Europski zakoni nešto su restriktivniji od primjerice američkih, te se

prema zakonu Europske Unije na web stranici moraju istaknuti pravila privatnosti organizacije koja je vlasnik te web lokacije. Postoje dvije osnovne vrste informacija o korisnicima koje bi vlasnici stranica trebali razlikovati (Clifton, 2010):

- **Informacije koje onemogućuju identifikaciju pojedinaca** – to su anonimni agregirani podaci koji se ne mogu koristiti za identifikaciju pojedinih korisnika, već služe za poboljšanje korisničkog iskustva. Ovi podaci ne ugrožavaju privatnost korisnika.
- **Informacije koje omogućuju identifikaciju pojedinaca**– ovo se odnosi na prikupljanje osobnih podataka o korisnicima kao što su: ime, adresa, spol i slično. Ovakvi podaci ugrožavaju korisničku privatnost i njihovo prikupljanje regulirano je zakonom u većini demokratskih država. Stoga je važno da web lokacija zatraži dopuštenje od korisnika za prikupljanje ovih podataka.

Kako bi se zaštitili korisnici od problema kao što su krađa identiteta, računalni virusi i nelegalno prikupljanje podataka, vlasnici web lokacija mogu poduzeti sljedeće određene mjere (Hassler, 2010 navedeno u Hausmann, 2012):

- Postaviti izjavu o privatnosti podataka na web lokaciju
- Koristiti kolačiće umjesto IP adresa
- Ne kombinirati agregirane podatke sa osobnim podacima korisnika
- Dati korisnicima mogućnost da isključe praćenje
- Razmotriti lokaciju na kojoj se spremaju podaci (i pravila privatnosti ukoliko se radi o ASP-u)

3. ALATI ZA WEB ANALITIKU

3.1. Općenito o alatima

Softver za web analitiku prati korisničku aktivnost na stranicama organizacije i drugih online kanala, u svrhu optimizacije korisničkog iskustva, prihoda, konverzije i slično. Podaci i izvješća dobiveni iz softvera za web analitiku koriste se za evaluaciju i poboljšanje učinkovitosti online prisutnosti organizacije (TrustRadius, 2014). Prilikom odabira adekvatnog alata postoji više područja o kojima treba voditi računa:

- Funkcionalnosti alata – predstavlja jedno od najvažnijih i najkompleksnijih područja u odabiru alata za WA, stoga je odabrano kao temelj komparacije alata u ovom radu. Opširnije o funkcionalnostima govori se u poglavlju 3.1.3.
- Pouzdanost i podrška dobavljača – podrška dobavljača odnosi se na dostupnost priručnika i dokumentacije, online podršku i korisničku službu, update softvera i sl.
- Troškovi – vrlo važan kriterij u odabiru alata koji se ne odnosi samo na cijenu softverskog rješenja, već i mnoge druge troškove. Ukupna cijena vlasništva nad alatom za WA ovisi o dobavljaču, te o odabranoj opciji. Generalno, u izračunu treba uzeti u obzir sljedeće: troškove po pregledu stranice, inkrementalne troškove (primjerice cijenu dodatnih funkcionalnosti i sl.), godišnje troškove podrške nakon prve godine, troškove profesionalnih usluga (primjerice instalacije, prilagodbe i sl.), troškove eventualnog dodatnog hardvera koji je potreban, te administrativne troškove (troškovi analitičara ili dodatnih zaposlenika). Poduzeća trebaju odabrati između besplatnih i komercijalnih alata, ovisno o poslovnim potrebama (Kaushik, 2010).
- Tehnički aspekti – obuhvaćaju hardverske i softverske zahtjeve, jednostavnost instalacije, kompatibilnost sa drugim softverima, sigurnost, itd.
- Usklađenost alata sa poslovnim zahtjevima poduzeća

3.1.1. Razvoj alata za WA

Prvi alati za web analitiku pojavili su se već u početku razvoja World Wide Web-a, a jedan od prvih alata za rudarenje Analog razvio je Stephen Turner 1995 (Wu *et al.*, 2009 navedeno u Hausmann, 2012) što se smatra rođenjem web analitike (Kaushik, 2007 navedeno u Hausmann, 2012). Prvi alati prikazivali samo osnovne metrike, primjerice posjete i preglede stranica, a podaci su prikupljeni metodom log datoteka (Hausmann, 2012). Danas se može govoriti o drugoj generaciji alata za WA koji prikupljaju širok raspon različitih podataka i prezentiraju ih u obliku korisnih informacija.

U novije vrijeme, pod utjecajem koncepta web analitike 2.0. koji se zalaže za prikupljanje kvantitativnih i kvalitativnih podataka, poduzeća često u kombinaciji sa tradicionalnim alatima za web analitiku koriste i druge alate koji nude funkcionalnosti kao što su: praćenje učinkovitosti na društvenim mrežama(koje postaju sve važniji način komunikacije s kupcima), prikupljanje povratnih informacija od posjetitelja, mobilnu web analitiku čiji udjel u prometu web stranica sve više raste, A/B testiranje, multivarijantno testiranje i slično. Ili odabiru alate koji nude kombinaciju praćenja tradicionalnih metrika i navedenih dodatnih funkcionalnosti.

3.1.2. Kategorizacija alata

Alati za web analitiku mogu se kategorizirati prema nekoliko kriterija. Prva podjela može se izvršiti prema metodama prikupljanja podataka, koje su opisane ranije u poglavlju 2.4. Drugo, mogu se klasificirati prema načinu pristupa funkcionalnostima web analitike. Stoga, alati za WA mogu biti dostupni u obliku *softvera kao usluge* (SaaS – software as a service) kojeg nude ASP-ovi (pružatelji usluge) ili kao *softver instaliran na računalu organizacije* (Nakatani & Chuang, 2011). Application service provider (ASP) je organizacija koja isporučuje aplikaciju i povezane usluge mrežnim putem većem broju korisnika, po principu modela iznajmljivanja ili naplate temeljene na korištenju ponuđene usluge (Gartner IT Glossary, 2014). Prednosti ovog modela su brza instalacija kroz nekoliko sati ili dana, manji troškovi koji se otplaćuju u mjesečnim

iznosima, te činjenica da je za unapređivanje softvera odgovoran pružatelj usluge. Nedostaci su niska razina personalizacije za pojedinog klijenta, te problemi integracije sa ostalim podacima prikupljenima pomoću drugih izvora. Odabirom druge opcije - kupnje licence softvera, dobiva se vlasništvo nad podacima i softver se nalazi unutar organizacije, a mogućnost personalizacije prema potrebama korisnika je visoka. Nedostaci u ovom slučaju su dulje vrijeme instalacije koja može potrajati tjednima ili čak mjesecima, te viši inicijalni troškovi nabavke, ali i troškovi održavanja.

Treće, alati se mogu klasificirati prema uređajima koji se koriste za pristup web stranici. Tako se mogu razlikovati mobilna i ne-mobilna web analitika. Iako danas sve više ljudi koristi pametne telefone za pristup internetskim stranicama, neke metode prikupljanja podataka ne funkcioniraju na mobilnim uređajima. Četvrto, alati za WA mogu se razlikovati s obzirom na vremenski razmak od prikupljanja podataka do trenutka kada je analitika dostupna. Neki alati mogu izračunati podatke u gotovo realnom vremenu, dok je drugima potrebno čak 15 ili više minuta za prezentiranje podataka (Nakatani & Chuang, 2011).


3.1.3. Funkcionalnosti alata za web analitiku

Funkcionalnosti alata odnose se na mogućnosti snimanja podataka, praćenja metrika i statistika, te generiranja izvještaja. Mogu se razlikovati dvije vrste funkcionalnosti: funkcionalnosti potrebne za prikupljanje podataka i dodatne funkcionalnosti. Ovisno o različitim softverskim rješenjima dodatne funkcionalnosti mogu biti: više-jezična podrška, podrška za različite vremenske zone, mogućnost prepoznavanja lažnog prometa na stranici, mogućnosti vizualizacije, itd. (Bothma & Fourie, 2007). Rijetki alati obuhvaćaju sve funkcionalnosti, a cijena implementacije takvih robusnih alata je vrlo visoka. Besplatni ili cijenovno dostupni alati možda neće imati sve funkcionalnosti koje su potrebne organizaciji. Potrebno je utvrditi poslovne potrebe i prema tome odabrati rješenje za web analitiku ili se odlučiti za kombinaciju od nekoliko alata koji će ispuniti sve zahtjeve.

Pregledom literature o alatima za web analitiku (Nakatani & Chuang, 2011, Sharon, 2011 te Creese & Veytsel, 2000) izdvojene su funkcionalnosti alata:

- **Tradicionalno izvještavanje** koje uključuje:
 - Općenite izvještaje kao što su broj posjeta, posjetitelja ili pregledanih stranica
 - Profile posjetitelja - podaci koji opisuju posjetitelje i omogućuju njihovu karakterizaciju, primjerice: rezolucija ekrana, poštanski broj, ukupni posjeti, ukupna vrijednost kupnji. Mogu varirati od osnovnih do kompleksnih podataka.
 - Profile ponuda - opis web sadržaja i proizvoda koje određeni korisnik pregledava. U najjednostavnijem obliku pojavljuje se kao lista datoteka koje su prikazane određenom posjetitelju.
- **Snimanje podataka** - može se odvijati unutar organizacije korištenjem web log datoteka, packet sniffinga ili web beaconsa koji snimaju podatke iz log datoteka sa servera organizacije. Drugi način je snimanje podataka putem preglednika posjetitelja pomoću JavaScript koda, a ovu metodu u pravilu koriste ASP dobavljači. Snimanje podataka može varirati prema granularnosti odnosno mogućnosti prikupljanja podataka na različitim stupnjevima detaljnosti. Također, varira i ovisno o širini podataka, odnosno mogućnostima prikupljanja različitih vrsta podataka i podataka iz različitih izvora kao što su videa, blogovi, Flash, RSS, itd.
- **Integracija podataka**- temelji se na ideji da prikupljeni podaci o web prometu predstavljaju samo dio seta podataka koji organizacija posjeduje o posjetiteljima. Stoga se, ovisno o poslovanju poduzeća, clickstream podaci mogu integrirati sa ostalim podacima kupaca (osobni podaci, kupčeve primjedbe, rezultati upitnika), informacijama o prodaji (svi podaci o kupnjama kupca), te različitim drugim poslovnim podacima (Peterson, 2004).
- **Analiza i prezentacija podataka** – analiza podataka provodi se različitim analitičkim tehnikama kao što su: segmentacija, A/B testiranje, SEO, funnel analiza, analiza puta posjetitelja, itd. Također, mogu se provoditi ad hoc analize, te analize povijesnih podataka. Ad hoc analiza vrlo je korisna metoda koja omogućuje izradu specifičnih izvještaja koji nisu predefiniрани u alatu, za različite poslovne potrebe. Svaki alat nudi mogućnost izvještavanja, a obično se radi o strukturiranim izvještajima uz grafove i

dijagrame. Sofisticiranija rješenja za web analitiku nude OLAP alate koji omogućuju drill down analizu. Uz uobičajene vizualizacije grafikonima, vrlo je popularno i korištenje alata za vizualizaciju kao što su Heat Maps, Scroll Maps, te Click Maps kojima se primjerice može prikazati gdje posjetitelji najviše klikaju i što im privlači pozornost.



Slika 8: Primjer funkcionalnosti praćenja klikova posjetitelja pomoću toplinske mape alata Clicktale

Izvor: <https://www.clicktale.com/academy/blog/eye-tracking-for-everyone/>

3.2. Tržište

Glavni pokretači suvremenog tržišta web analitike su konstantan rast u online kupnji, automatizacija marketinga, te rastući prelazak na online vođenje poslovanja. Generiranje sve većih količina podataka na webu uzrokuje potrebu za njihovom kvalitetnom analizom kako bi se dobile informacije o prodaji, uspjehu marketinških aktivnosti i online strategije. Tijekom godina, alati za WA evoluirali su od aplikacije koja služi samo za praćenje osnovnih metrika, do

sofisticirane aplikacije koja je sposobna integrirati brojne alate za različite namjene. Na tržištu dominiraju besplatna analitička rješenja, ali kontinuirano se povećava i prisutnost komercijalnih alata za web analitiku (Analytics Magazine).


Za potrebe današnjeg poslovanja organizacije žele softver koji neće služiti samo za jednostavno izvještavanje, već rješenje koje će pružati podršku u složenim marketinškim izazovima i nositi se sa velikim količinama kompleksnih podataka. Stoga, nastojeći zadovoljiti takve potrebe, dobavljači i cjelokupno tržište idu u smjeru povećanja funkcionalnosti alata, ali istovremeno teže pojednostavljenju alata, kako bi ih mogli koristiti zaposlenici koji nisu vrhunski eksperti u području analize podataka.

Globalno tržište web analitike 2014. godine vrijedilo je 1.33 bilijuna dolara (od čega 0,36 bilijuna dolara otpada na europsko tržište), a procjenjuje se da će do 2019. godine vrijednost porasti na čak 3,09 bilijuna dolara. Dok je procjena da svjetsko tržište WA ima godišnji rast od 18,3 %, europsko tržište ima nešto niži rast od 16,1 % (Micro Market Monitor, 2015).

S obzirom da tvrtke biraju alate prema svojim poslovnim potrebama, može se govoriti o liderima za pojedine tržišne niše, ovisno o veličini poduzeća. U istraživanju koje je provela organizacija TrustRadius koja ocjenjuje softvere na temelju ocjena korisnika definirani su tržišni lideri za pojedine skupine poduzeća. Tako je za mala poduzeća (manje od 51 zaposlenika) Google Analytics najpopularniji izbor, s obzirom da svojim budžetom ne mogu priuštiti skupe alate, a njihovo poslovanje ne zahtjeva kompleksne funkcionalnosti koje nude tavi alati. Također popularan i dobro ocijenjen od korisnika je i besplatni alat Statcounter. Google Analytics lider je i u kategoriji poduzeća srednje veličine (51 do 500 zaposlenika), ali tu ima snažnog konkurenta u alatu Adobe Analytics. TrustRadius navodi i da niti jedan dobavljač softvera za WA analitiku nije fokusiran na kategoriju srednjih poduzeća. U skupini velikih poduzeća (više od 500 zaposlenika) Adobe Analytics lider je bez značajne konkurencije (Akhtar, 2014).

Prema Datanyze servisu koji izrađuje različite grafike na temelju recentnih podataka, na Slici 8. prikazano je korištenje pojedinih web alata u svijetu u postotcima (izračun se odnosi na sve web stranice koje prati ovaj servis). Tako se može vidjeti da dvije verzije softvera tvrtke Google

zajedno koristi 78 % web lokacija u svijetu, što čini Google nedodirljivim liderom na tržištu. Softver Omiture tvrtke Adobe zauzima primjerice tek 11. mjesto na cjelokupnom tržištu. Od alata koji će se analizirati u ovom radu, značajniji udjel na tržištu imaju comScore, Piwik i StatCounter.



Slika 9: Postotak korištenje alata za Web analitiku u svijetu (prosinac, 2016.)

Izvor: <https://www.datanyze.com/market-share/Analytics/>

3.3. Pregled odabranih alata

Pregledom literature i relevantnih internetskih portala i članaka odabrano je dvadeset alata za web analitiku čije će se funkcionalnosti prvo analizirati korištenjem sekundarnih izvora, a potom usporediti od strane istraživača. Među alatima se nalaze komercijalni, ali i besplatni alati, s obzirom da cijena nije kriterij usporedbe u ovoj analizi. Većina odabranih alata prikuplja podatke metodom tagiranja stranica. Cilj usporedbe je potvrditi postavljenu hipotezu:

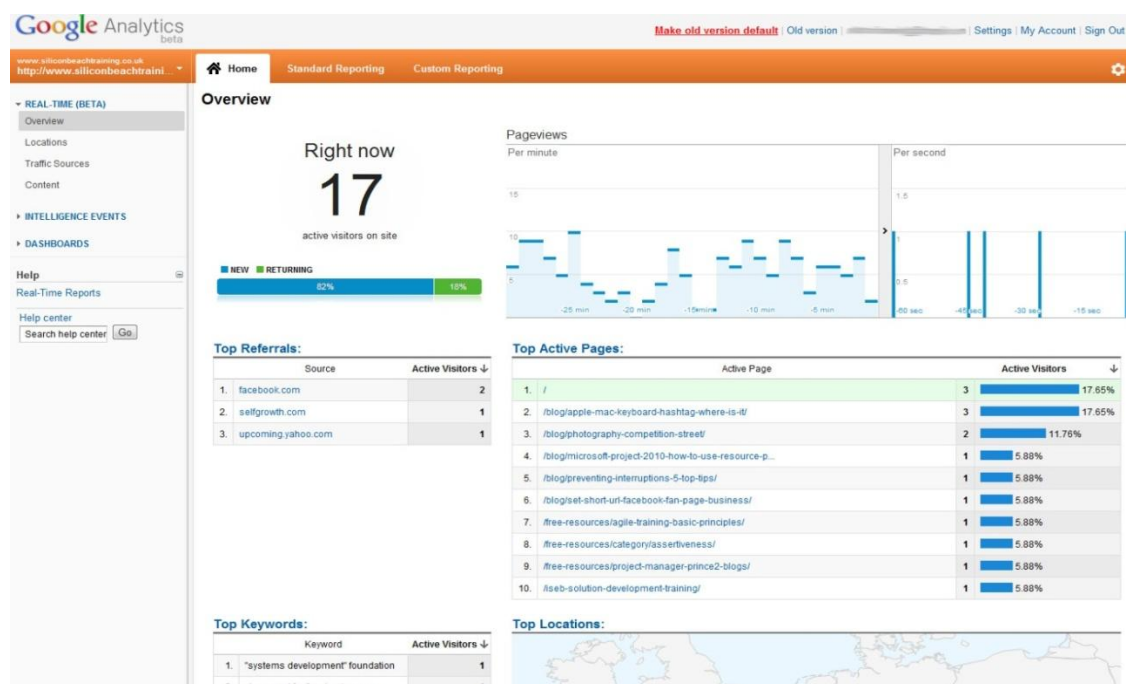
H₁: Postoje razlike u razini kvalitete funkcionalnosti alata za web analitiku

3.3.1. Google Analytics

Potpuno je besplatan alat, te je najrašireniji softver za web analitiku u svijetu. Nastao je kao prepakirana verzija Urchina na zahtjev, koji je Google preuzeo 2005. godine (Demers, 2013). Popularan je upravo zbog velikog broja funkcionalnosti koje podržava, što nije karakteristično za besplatne alate. Besplatna verzija omogućena je za web lokacije sa najviše 5 milijuna pogleda mjesečno ili za neograničeni broj pogleda ukoliko je lokacija integrirana sa AdWords računom. Google-ov AdWords je oglašivački program koji je vrlo popularan u oglašavanju malih kompanija, a funkcionira na načelu pay per click, odnosno plaćanje po kliku. Dodatna je prednost što se Google Analytics račun lako može povezati sa AdWords računom i na taj način automatski pratiti uspješnost PPC kampanja. Za prikupljanje podataka, Google Analytics koristi metodu tagiranja stranica, a s obzirom da se radi o SaaS (softver kao usluga) rješenju, Google preuzima brigu o prikupljanju i obradi podataka. Omogućeno je slanje podataka o korisničkoj interakciji sa ostalih internetski povezanih lokacija poduzeća (npr. pozivni centar, intranet) u svrhu analize. Ovaj alat omogućuje prikupljanje različitih podataka o posjetiteljima kao što su: IP adresa, grad i država, internet preglednik, ISP, operacijski sustav, korisničko ime, itd. Omogućuje praćenje osnovnih metrika, ali i posebnih metrika prilagođenima poslovanju, te se može koristiti za praćenje internet trgovine. Posebice je koristan u praćenju izvora prometa, te odakle posjetitelji dolaze. Također je moguće pratiti i Evente (događaje) kao što su download sadržaja, Flash eventi, prikaz multimedije, RSS Feed Subscriptions, pogreške na stranici. Od analitičkih tehnologija Google Analytics nudi napredne mogućnosti segmentacije prema različitim kriterijima, SEO analizu, A/B testiranje sadržaja, vizualni prikaz konverzijskog ljevka (npr. praćenje kupnje ili procesa pretplate), te mjerenje konverzije, odnosno ostvarivanja ciljeva. Zadavanje ciljeva kroz ovaj alat je vrlo jednostavno i omogućava interpretaciju podataka usporedbom više faktora odjednom, primjerice moguće je doznati koliko je osoba određenog spola i određene dobi na određenoj geografskoj lokaciji ostvarilo konverzija u promatranom vremenskom razdoblju (Bekavac, 2014). Ipak, broj ciljeva je limitiran na 20 po jednom pogledu.

Alat podržava i provođenje ad hoc analiza, te analizu podataka u realnom vremenu, te analizu povijesnih podataka. Izvještaji se mogu vizualizirati pomoću pivot tablica, dijagrama, grafikona kretanja (kojima se uspoređuju metrike kroz vrijeme), a dostupne su i mape podrijetla posjetitelja, te mape klikova na stranici. GA vrlo je prilagodljiv alat i omogućuje postavljanje djeljivih kontrolnih ploča sa specifičnim upitima, te kreiranje specifičnih izvještaja uključujući i benchmarking izvještaje u svrhu usporedbe sa drugim anonimnim korisnicima Google Analyticsa. U području integracije omogućen je izvoz podataka u različitim formatima (CSV, TSV, PDF, XML), integracija sa dodatnim alatima (AdWords, Google Display Network). Prednost ovog alata je što omogućuje postavljanje upozorenja za vrijednosti metrika i događaja koje nisu uobičajene.

Dodatne prednosti ovog alata su u tome što je dostupan na 31 jeziku i što može biti primijenjen na web, mobilna i druga digitalna okruženja, ima mogućnost online obuke, te nudi mobilnu aplikaciju. Kao nedostaci ovog alata mogu se navesti prilična opsežnost alata za korisnike početnike, te potreba za kontinuiranim učenjem zbog konstantnih poboljšanja (koja su prednost), te uzorkovanje podataka.



Slika 10: Primjer Google Analytics korisničke ploče sa podacima u realnom vremenu

Izvor: <https://www.siliconbeachtraining.co.uk/blog/google-analytics-real-time-reporting-first-look>

3.3.2. Google Analytics 360

Tvrtka Google objavila je komercijalnu verziju Google Analytics alata 2011. godine namijenjenu prije svega velikim poduzećima. Najveću prednost u odnosu na besplatnu verziju čine dodatne opcije podrške i obuke, te integracija sa dodatnim alatima namijenjenima velikim poduzećima (TrustRadius, 2014). U području prikupljanja podataka razlika u odnosu na besplatnu verziju je što komercijalna verzija ima mnogo veći limit za iznos podataka koji se može prikupiti, nudi veći broj prilagođenih dimenzija i metrika (200 za svaku u odnosu na 20 u besplatnoj verziji), te veću fleksibilnost u organiziranju podataka. Ova verzija softvera omogućuje integraciju sa DoubleClick platformom za oglašavanje, alatom BigQuery za rudarenje podataka, te uvoz podataka iz brojnih izvora uključujući pregled povijesnih podataka. Što se tiče izvještavanja, razlike u odnosu na besplatnu verziju nisu velike. Najveća prednost u verziji 360 je što koristi poseban algoritam koji analizira i modelira kako različiti kanali utječu na konverziju posjetitelja. Dodatno, poboljšane su opcije izvještavanja o tijeku aktivnosti korisnika na stranici. Jedna od većih prednosti je Google Analyticsa 360 je što eliminira uzorkovanje podataka čime omogućava kvalitetne analize cjelokupnih podataka, a ujedno mnogo brže generira ac hoc izvještaje, čak i onih kompleksne. U ovoj verziji poboljšano je i segmentiranje te primjena segmenata u izvještajima. Područja na kojima ovaj alat trenutno ima manjkavosti su: prilagođenost e-trgovini, funkcionalnosti A/B testiranja i analitike na stranici, izrada prilagođenih izvještaja, te nedovoljna opsežnost online dokumentacije za ovu verziju softvera (TrustRadius, 2014).

3.3.3. Piwik

Piwik je besplatni, open-source alat kreiran od strane programera diljem svijeta, lansiran 2007. godine. Često se naziva alternativom Google Analyticsu, no za razliku od GA, ovaj alat nije SaaS rješenje stoga zahtijeva uslugu poslužitelja (TrustRadius, 2014). Tim koji stoji iza ovog softvera omogućuje i Piwik PRO verziju (orijentiranu velikim poduzećima) koja uključuje hosting u oblaku ili opciju instalacije softvera na računala, te analitičko savjetovanje za

korisnike, a cijene se kreću ovisno o godišnjim planovima korištenja. Prikupljanje podataka vrši se metodom tagiranja stranica, a podaci se pohranjuju na serveru poduzeća koje ima kontrolu nad podacima. Ovaj alat ima i skriptu koja omogućuje uvoz podataka prikupljenima web logovima. Dodatne pogodnosti u području prikupljanja podataka su praćenje neograničenog broja stranica, blokiranje URL-ova i IP adresa po želji, nepostojanje ograničenja u količini podataka, te praćenje korisnika na mobilnim uređajima. Ovim alatom mogu se pratiti sve potrebne metrike prometa na stranici (osnovne i nešto naprednije poput stope odustajanja, stope izlaska, itd.) i aktivnosti korisnika. Mogu se dodavati prilagođene dimenzije i varijable koje se potom mogu vizualizirati. Omogućuje prikupljanje detaljnih informacija o posjetiteljima (IP adresa, grad, država, operacijski sustav, ISP, vrsta i jezik preglednika, rezolucija ekrana) i praćenje događaja – download sadržaja, Flash, te RSS. Od besplatnih analitičkih tehnologija može se izdvojiti segmentacija (nije detaljna i dubinska), analiza pretraživanja na stranici, te jednostavno postavljanje i praćenje ciljeva. Za opcije kao što su A/B testiranje, analitika medijskog sadržaja, vizualni prikaz konverzijskog lijevka, ili vizualizacija korisničkog puta na stranici potrebno je kupiti i instalirati dodatne plug-ine iz Piwik trgovine. Jedna od zanimljivih opcija je što omogućuje uvid u trenutnu i povijesnu vrijednost metrika za bilo koji redak u izvještaju. Omogućuje rangiranje najboljih ključnih riječi, te prikazuje podatke o prometu u realnom vremenu, a uz instalaciju plugina ima mogućnost izrade ac hoc izvještaja. Vizualizacije uobičajenim grafikonima su kvalitetne i jasne, a prikazuje se i mapa podrijetla posjetitelja. Zanimljiva je funkcionalnost usporednog grafičkog prikaza dviju ili više metrika kroz vrijeme. Kontrolne ploče mogu se izraditi i odlično prilagoditi potrebama korisnika dodavanjem widgeta, a postupak je vrlo intuitivan. Piwik se može integrirati sa brojnim aplikacijama namijenjenima CMS-u, e-trgovini i sl. što ga čini vrlo prilagodljivim alatom. Podaci se mogu eksportirati u više formata kao što su CSV, PHP, TSV i XML. Postavljanjem upozorenja za vrijednosti KPI-jeva može se nadgledati poslovanje. Prednosti alata su što je dostupan na više od 50 jezika, ima mobilne aplikacije, te je korisnik vlasnik podataka koji se prikupljaju. Nedostaci ovog alata mogu se pronaći u nedostatnim funkcionalnostima i dokumentaciji za e-trgovinu, te generalno nedovoljno opsežna dokumentacija, kao i potreba za većim tehničkim vještinama korisnika za razliku od drugih alata.

3.3.4. IBM Digital Analytics (Coremetrics)

IBM je 2010. godine preuzeo Coremetrics i preimenovao ga u Digital Analytics, te restrukturirao postojeće analitičke mogućnosti alata. Radi se o komercijalnom alatu sa brojnim kvalitetnim funkcionalnostima, baziranom na radu u oblaku, a posebno je pogodan za analitiku velikih tvrtki i e-trgovina zbog pružanja opsežnih podataka o vrijednosti kupnji koje nisu realizirane, kupljenim ili pregledanim proizvodima i drugim statistikama (TrustRadius, 2014). Jedna je od komponenti u mnoštvu analitičkih proizvoda koje nudi tvrtka IBM, kao što su primjerice opcionalni dodatak IBM Digital Analytics Multisuite namijenjen velikim poduzećima ili IBM Tealeaf alat za analizu korisničkog iskustva. S obzirom da IBM omogućava veliki broj plug-ina uz ovaj alat moguće su brojne dodatne analitičke funkcionalnosti. Podaci se prikupljaju metodom tagiranja stranica, te se zahtjevi šalju na servere IBM-a. Alat nudi veliki broj različitih vrsta metrika potrebnih u poslovanju. Omogućeno je prikupljanje podataka o događajima kao što su: pregled stranice, pregled proizvoda, pregled kolica, pregled registracije, konverzija i sl. Ovi podaci korisni su za e-trgovine jer mogu dobiti uvid u informacije korisne za unaprjeđenje marketinga (primjerice podaci o najprodavanijim proizvodima ili proizvodima koji imaju malo pregleda, ali velike stope konverzije). IBM LIVE(Lifetime Individual Visitor Experience) profili prate i pohranjuju dugoročno sve korisničke interakcije sa poduzećem, uključujući povijest pretraživanja, e-mail interakciju, prikazivanje oglasa i sl. Neke od funkcionalnosti izvještavanja ovog alata su limitirane. Dostupna je prilagođena segmentacija, ali povijesni podaci mogu se segmentirati samo za zadnja 93 dana, dok su kod primjerice u Google Analytics alatu podaci dostupni desetak godina unazad (Bull, 2016). Segmentacija omogućuje analizu korisničkog ponašanja kroz više sesija, vremenskih perioda i kanala, ali nije primjenjiva na svim izvještajima. Alat nudi i standardni izvještaj puta posjetitelja koji daje uvid u kretanje posjetitelja kroz konverzijski lijevak (Visconti, 2015), te omogućuje ad hoc postavljanje ciljeva. Korisni su i izvještaji o pretraživanju na stranici koji se mogu koristiti za optimizaciju pretraživanja stranice. Osim ovih mogućnosti mogu se ugraditi i dodaci kao što je Digital Recommendations koji omogućuje A/B testiranje i koristi se za preporučivanje proizvoda kupcima dok pregledavaju stranicu, te dodatak Livemail koji je namijenjen e-trgovinama i koristi se za e-mail marketing kupcima koji su napustili proces kupnje proizvoda iz košare. Podaci i metrike nisu u potpunosti u realnom vremenu, već imaju malu odgodu. Predefinirani izvještaji su prilagodljivi, te se mogu

analizirati povijesni podaci. Prilagođeno izvještavanje je limitirano na određeni broj izvještaja za svaki mjesec, iza kojeg stoje i dodatni troškovi. Prednost ovog alata svakako su kvalitetni marketinški izvještaji sa modelima doprinosa pojedinih kanala. Osim uobičajenih grafikona, ovaj alat nudi vizualizaciju izvještaja pomoću toplinskih mapa (dostupne samo za neke vrste izvještaja), te Venn dijagrama kojima se mogu analizirati kombinacije marketinških kampanja. Alat nudi predefinirane kontrolne ploče od kojih svaka prikazuje podatke o performansama za različita područja, ali se one ne mogu uređivati. Nudi i mogućnost izrade vlastitih prilagodljivih kontrolnih ploča, koje se mogu dijeliti i slati putem e-maila (IBM, 2014). Omogućena je opcija eksporta detaljnih prilagođenih podataka o korisnicima i izvoz dnevnih analitičkih podataka u skladište podataka. Dodatna prednost je jednostavna implementacija alata, modul benchmarkinga za usporedbu sa konkurentima, te vrlo efektivna i kvalitetna korisnička podrška. Jedan od većih nedostataka je visoka cijena ovog alata, dostupna samo većim tvrtkama, a nedostatak je i kompleksno i usporeno korisničko sučelje.

3.3.5. Webtrends Infinity

Webtrends je kompanija osnovana 1993. godine, te nudi različita analitička rješenja ovisno o potrebama klijenata. Glavni proizvod trenutno je komercijalni softver Webtrends Infinity u obliku SaaS rješenja (klijenti posjeduju podatke), objavljen 2016. godine. Ovaj alat prikuplja podatke standardnim JavaScript tagovima, te omogućuje upravljanje tagovima i kreiranje prilagođenih tagova za prikupljanje različitih podataka. Podaci se prikupljaju na razini pojedinog posjetitelja, a uključuju podatke o sesijama posjetitelja i podatke o događajima. Omogućuje prikupljanje neograničenog broja parametara, te nema limit na broj pregleda stranice. Također, nema uzorkovanja podataka, već se koriste cijeli setovi podataka, kako bi se mogli modelirati validni statistički trendovi. Alat daje holistički prikaz odakle promet dolazi, na koje stranice posjetitelji idu i što rade na stranici. Od analitičkih tehnologija podržava kvalitetno segmentiranje i kreiranje klastera, primjenu segmenata na izvještaje u realnom vremenu. Osim toga omogućeno je i eksportiranje segmenata u svrhu primjene različitih marketinških kampanja na pojedine klastere. Također, nudi i napredno izvještavanje za konverziju, put posjetitelja,

doprinos kanala, te kvalitetan uvid u to odakle dolazi promet (sa kojih uređaja, stranica, plaćenih klikova ili obične pretrage). Ovaj alat može izvršiti neograničeni broj ad hoc upita koji uključuju analizu podataka do najviših razina detaljnosti i dopušta postavljanje bilo koje varijable za dimenziju. Svi izvještaji, mjere i dimenzije su dostupni u realnom vremenu, a mogu se ponovno analizirati i povijesni podaci primjenom prilagođenih mjera. Alat nudi standardne kategorije predefiniраних izvještaja za kampanje, sadržaj, ljude, promet i sl, ali i napredne. Kontrolne ploče su prilagodljive, a korisničko sučelje je intuitivno.

Prednosti alata su mogućnost konsolidiranja svih online i offline podataka o posjetiteljima, te objedinjeni pogled na podatke prikupljene putem svih digitalnih kanala, domena i uređaja. Alat nudi vizualizaciju svih izvještaja i metrika u realnom vremenu pomoću grafikona te vizualizira put korisnika, a omogućuje i izradu prilagođenih vizualizacija. Za napredne opcije omogućuje eksport izvještaja u alate za vizualizaciju. Izvještaji i podaci na razini posjetitelja mogu se eksportirati u raznim formatima uključujući JSON, XML, CSV.

3.3.6. Mint

Ovo je komercijalni softver koji se instalira na računalima organizacije i konfigurira sa serverima organizacije, namijenjen prije svega malim i poduzećima srednje veličine zbog svoje cjenovne dostupnosti. Podaci se prikupljaju JavaScript tagovima. Ovaj alat je sličan Google Analyticsu prema podacima koje prikuplja, no podaci nisu toliko iscrpni kao kod GA. Osnovne funkcionalnosti koje ima ovaj alat su:

- Sekcija Posjetitelji – prikazuje ukupne i jedinstvene posjetitelje, a statistike se mogu pregledati prema zadnjim danima, tjednu, mjesecu ili godini.
- Sekcija Izvor Prometa – izvori se mogu pregledati prema najnovijim ili najčešćima, te prema domeni.

- Sekcija Pretrage - prikazuje najpopularnije pojmove koje ljudi koriste koji bi pronašli stranicu poduzeća. Zanimljiva je opcija zaseban pregled prometa koji dolazi iz pretrage slika, koja može biti vrlo korisna za određene vrste web lokacija.
- Sekcija Stranice – prikazuje najpopularnije stranice i sadržaje na stranici
- Sekcija Bird Feeder – mjeri trendove kretanja pretplata na novosti prema razdobljima
- Sekcija User Agent 007 – služi za praćenje informacija o posjetiteljima kao što su verzija preglednika, rezolucija, platforma, verzija Flash plugina, itd.

Nedostaci ovog alata su u tome što ne mjeri neke važne metrike kao što su: stopa odustajanja, vrijeme na stranici i ostale mjere angažmana posjetitelja, te ne omogućuje „kopanje“ po podacima (Melaugh, 2011). Dodatno, alat ne omogućuje napredne opcije poput A/B testiranja, praćenja konverzija i analize konverzijskog lijevka. Iako ne nudi ad hoc izvještaje, omogućuje jednostavne predefinirane izvještaje sa dostupnim podacima i statistikama u realnom vremenu. Prednosti alata su visoka prilagodljivost kroz instalaciju dodatnih funkcionalnosti koje alat ne podržava putem brojnih ekstenzija koje se nazivaju „Peppersi“, lijepo sučelje, te prilagodljive kontrolne ploče koje omogućuju kvalitetan prikaz live statistika. Transakcijski podaci mogu se eksportirati u CSV formatu. Dodatna prednost je niska cijena koja se plaća samo jednom na početku za svaku stranicu koja se prati. Kao dodatan nedostatak bi se mogao navesti potrebne tehničke vještine za instalaciju i konfiguraciju alata.

3.3.7. Mixpanel

Mixpanel je softverski proizvod istoimene kompanije koji se nudi kao usluga u oblaku, a lansiran je 2009. godine. Platforma je dizajnirana za praćenje korisničkog ponašanja na web-u, ali i na mobilnim uređajima. U usporedbi sa „klasičnom“ analitikom koja se fokusira na ukupne trendove, ovaj alat prije svega služi korisnicima za pregled onoga što se događa na razini individualnog posjetitelja. Struktura plaćanja pomalo je komplicirana; moguće je besplatno korištenje do 25000 jedinica podataka mjesečno, a iznad toga plaćaju se pojedinačno broj događaja i ljudi koji se prate. Prikupljanje podataka vrši se metodom tagiranja stranica. Ovaj alat

fokusira se na praćenje metrika za opisivanje angažmana posjetitelja, te praćenje događaja, ali primjerice ne prati tradicionalne metrike, kao što su broj pregleda stranice, duljinu sesije i sl. Omogućuje korisnicima da sami odaberu koje metrike će im se prikazivati. Također, moguće je povezati postojeće podatke iz poduzeća i pomoću sekcije „People“ izraditi profile kupaca u okviru kojih se spremaju podaci o njima i o njihovim aktivnostima na stranici, te ih pretraživati po potrebi. Alat nudi mogućnost segmentacije posjetitelja na temelju toga odakle dolaze i što rade na stranici, te A/B testiranje čak i unutar mobilne aplikacije. Vrlo korisna je i sekcija „Retention“ koja vizualno prikazuje koliko često se korisnici vraćaju na stranicu i koriste aplikaciju, te analizu kako promjene koje se rade na stranici ili aplikaciji utječu na zadržavanje kupaca. Prednost ovog alata je kvalitetna analiza konverzijskog lijevka, koja omogućuje postavljanje događaja koji će se pratiti i ciljeva, te izradu retroaktivnih lijevaka. U besplatnoj verziji alata povijesni podaci čuvaju se unatrag 60 dana, a u plaćenim verzijama duže. Alat omogućuje postavljanje ad hoc upita, a podaci se prikazuju u realnom vremenu.

Prednost je jasno i intuitivno korisničko sučelje koje sadrži vrlo kvalitetne vizualizacije, te omogućuje jednostavno dodavanje događaja u segmentaciju ili konverzijski lijevak (Trust Radius, 2014). Omogućena je i izrada prilagođenih grafikona, ali same kontrolne ploče nisu previše prilagodljive. Alat omogućuje slanje poruka korisnicima ovisno o njihovim aktivnostima, unutar aplikacije ili e-mailom, te kreiranje pravila kojima će se automatski slati poruke na temelju događaja koji se prate putem alata. Omogućen uvoz podataka, te izvoz sirovih podataka u Excel i ostale alate, ali manji nedostatak je što je izvoz moguć samo uz korištenje API-ja (aplikacijsko programsko sučelje). Dodatne prednosti su kvalitetne mobilne aplikacije, ankete za ispitivanje mišljenja korisnika, te kvalitetna i brza korisnička podrška. Kao nedostaci bi se mogli navesti formiranje cijene alata, te potrebne tehničke sposobnosti za integraciju alata sa web lokacijom (Fernando, 2014).

3.3.8. KISSmetrics

Ovaj alat više je fokusiran praćenje pojedinačnih posjetitelja stranice kroz različite uređaje, nego na agregirane podatke. Predstavlja SaaS rješenje namijenjeno poduzećima srednje veličine, no ima kupce iz svih tržišnih segmenata (Trust Radius, 2014). Cijena se kreće ovisno o potrebnim funkcionalnostima i broju događaja koji se prate. Slično kao i Mixpanel, prikuplja korisne podatke o aktivnosti pojedinih posjetitelja na stranici te omogućava kvalitetno praćenje događaja, dok su tradicionalne metrike o prometu na stranici zanemarene. Jedna od korisnih opcija ovog alata je što omogućava dodavanje parametara u URL, što omogućuje jednostavno praćenje događaja i ljudi (Fernando, 2014). Također, omogućuje pretraživanje grupa ljudi prema njihovim aktivnostima na stranici ili općenitim podacima, slanje e-mailova ili oglasa grupama, te kreiranje različitih izvještaja na temelju pretraga. Prikupljanje podataka vrši se metodom tagiranja stranica. Od analitičkih mogućnosti dostupna je segmentacija, kvalitetna analiza konverzijskog lijevka i puta korisnika (prikazuje najčešće korake koje korisnici prođu od prvog posjeta do postizanja cilja kojeg postavlja korisnik), A/B testiranje (nešto je kompleksnije nego kod ostalih alata jer zahtjeva korištenje zasebnog alata i korištenje JavaScript koda). Alat omogućuje podatke u realnom vremenu i praćenje korisničkih aktivnosti u realnom vremenu. Omogućuje vizualni prikaz zarade prema posjetiteljima i različitim marketinškim kanalima, te dizajniranje vlastitih ad hoc izvještaja i korištenje povijesnih podataka. Prednost alata je što omogućuje neograničen broj izvještaja. Ima lijepo i vrlo intuitivno sučelje, no sam alat nije toliko jednostavan za korištenje, a prilagodba alata zahtijeva tehničku podršku. Omogućuje automatsko slanje obavijesti poruka i mailova posjetiteljima na temelju njihovih aktivnosti na stranici, prema pravilima koje postavlja korisnik. Jedna od prednosti je i jednostavna integracija podataka iz alata u web stranicu ili aplikaciju za kupce, te objedinjeno praćenje korisnika putem različitih kanala (web, društveni i mobilni). Moguć je izvoz podataka u obliku JSON i CSV datoteka. Kao mana ovog alata na koju su ukazali neki od korisnika, pokazao se problem s integritetom podataka u izvještajima koji su pokazivali drugačije rezultate od ostalih alata (Trust Radius, 2014). Kao nedostaci se mogu navesti manjak metrika prometa na stranici, te dosta visoka cijena za poduzeća s manjim budžetom.

3.3.9. Woopra

Woopra je platforma koja je za razliku od tradicionalnih alata za web analitiku orijentirana prije svega na praćenje i mjerenje angažmana posjetitelja i prikazivanje trenutnih podataka. U početku se radilo o besplatnom alatu, no s vremenom se tvrtka orijentirala na plaćene verzije alata ovisno o broju aktivnosti i veličini poduzeća. Ciljaju na velika poduzeća, a alat je prilagođen različitim poslovnim sektorima. Woopra je SaaS rješenje koje prikuplja podatke metodom tagiranja stranica pomoću JavaScript koda. Važna funkcionalnost je AppConnect koja omogućuje povezivanje i sinkronizaciju podataka sa različitim aplikacijama i servisima. Ova funkcionalnost omogućuje kreiranje profila za svakog pojedinog korisnika i ažuriranje podataka u realnom vremenu, te pretraživanje korisnika. Ovaj alat namijenjen je uglavnom praćenju demografskih i podataka o ponašanju pojedinih posjetitelja, te događaja na stranici, a korisnici mogu prilagoditi alat za metrike koje žele pratiti. Svi prikupljeni podaci mogu se odmah analizirati različitim analitičkim metodama koje alat nudi. Na temelju korisničkih profila može se provesti kvalitetna segmentacija korisnika prema određenim događajima. Moguće je pratiti i korisnički put svakog posjetitelja u realnom vremenu. Analiza i vizualizacija konverzijskog ljevka omogućuje postavljanje aktivnosti kao ciljeva koji će se pratiti, a moguće je pratiti konverziju prema danu, platformi, industriji i sl. Još jedna korisna funkcionalnost su izvještaji o retenciji korisnika koji omogućuju uvid u to da li se korisnici vraćaju i izvršavaju ponovno aktivnosti kao što su kupnja, korištenje proizvoda, itd. Nudi standardne vizualizacije, kao i mape posjetitelja u realnom vremenu. Alat omogućuje izradu prilagođenih izvještaja i korištenje povijesnih podataka u izvještajima. Korisničko sučelje i kontrolne ploče imaju lijep izgled, no nedostaci su što prilagodba izgleda vizualizacija i kontrolne ploče može biti vrlo zahtjevna, a sama kontrolna ploča više je namijenjena stručnjacima, nego korisniku početniku. Alat nudi dobre mogućnosti integracije. Osim već spomenute integracije sa brojnim aplikacijama (Google Drive, Facebook, Dropbox, itd.), alat omogućuje aktiviranje određenih akcija kroz te aplikacije, prema pravilima postavljenima u alatu (primjerice pozivnica korisniku na chat ovisno o stranicama koje pregledava). Podaci iz izvještaja mogu se izvoziti u raznim formatima. Korisna funkcionalnost su obavijesti na stranici o važnijim aktivnostima posjetitelja u realnom vremenu koje omogućuju neposredno reagiranje, a dodatna prednost je i mobilna aplikacija.

3.3.10. Clicky

Smatra se kako je ovo jedan od najrobusnijih alata za web analitiku danas koji također osigurava podatke o prometu na stranici u realnom vremenu (Oberoi, 2015). Alat je namijenjen uglavnom malim i poduzećima srednje veličine. Što se tiče cijene, moguća je besplatna verzija za praćenje jedne stranice koja ima do 3000 pregleda dnevno, a ostale cijene kreću se ovisno o broju stranica koje se prate i pregledima stranica. Clicky je SaaS platforma, a podaci se prikupljaju metodom tagiranja stranica. Mogućnosti praćenja metrika su opsežne i gotovo se mogu usporediti sa Google Analytics alatom, no nešto je slabiji u području praćenja događaja na stranici (primjerice download sadržaja i Flash događaji mogu pratiti samo u premium verziji). Ovaj alat također omogućuje pregled svakog posjetitelja i aktivnosti koje obavlja na stranici, sa opcijom dodavanja prilagođenih podataka posjetiteljima (korisnička imena i e-mail adrese), te analizu svakog posjetitelja i pregled povijesnih podataka. Specifične funkcionalnosti su video analitika, te praćenje Twitter pretraga, pomoću koje se mogu pratiti tagovi, ključne riječi i retweetovi. Alat nudi i opsežne analitičke tehnike. Osim uobičajene segmentacije i filtriranja korisnika prema različitim kriterijima nudi napredne opcije analize konverzijskog lijevka (bez vizualizacije) te postavljanja i praćenje do 30 ciljeva. Dostupna je integracija sa SheerSEO servisom, te Visual Website Optimizerom za praćenje rangova i odvojeno testiranje. Omogućuje A/B testiranje, analizu puta posjetitelja, te mjerenje efektivnosti i zarade od marketinških kampanja. Moguća je i analiza te grafički prikaz trendova korištenjem povijesnih podataka.

U izradi izvještaja omogućeni su razni ad hoc upiti, te visoka razina detaljnosti. Uobičajene vizualizacije su lijepog izgleda. Od naprednih vizualnih mogućnosti mogu se izdvojiti toplinske mape za pojedine stranice, ali i za pojedinačne sesije posjetitelja i mape posjetitelja. Korisničko sučelje pomalo je komplicirano, pogotovo za korisnike početnike kojima može biti teško za snalaženje (Oberoi, 2015). Kontrolne ploče su visoko prilagodljive. Mogu se postaviti e-mail obavijesti za razne događaje kao što su konverzija, logiranje posjetitelja i sl. Izvještaji se mogu izvoziti u CSV, XML i PDF formatima. Alat se može integrirati pomoću plug-ina sa brojim CMS platformama, forumima, te servisima za kupnju kao što su Magento, PrestaShop i sl. (Kholod, 2015). Vrlo je koristan i widget unutar stranice sa live statistikama koje vide samo korisnici, ali ne i posjetitelji. Prednosti su i jednostavna instalacija, te mobilne aplikacije za

Android i iPhone. Nedostatak je što su važne funkcionalnosti kao što je praćenje ciljeva te izvještaji na e-mailu dostupne samo u premium verziji.

3.3.11. GoingUp

Platforma je koja omogućuje nudi usluge u oblaku (SaaS) i omogućuje kreiranje besplatnog računa preko kojeg se može pratiti više stranica. Podaci se prikupljaju metodom tagiranja stranica. Metrike koje se prikupljaju su standardne: broj posjetitelja, vrijeme na stranici, lokacija, vrsta internet preglednika, operacijski sustav i brzina internet veze posjetitelja, stope konverzije, najpopularnije stranice, itd. Jedna od važnih prednosti ove besplatne platforme je što nudi vrlo kvalitetne SEO alate sa sljedećim opcijama: analiza ključnih riječi koje dovode posjetitelje, provjera gustoće ključnih riječi na web stranici, alat za praćenje ranga na tražilicama prema pojedinim ključnim riječima, te alat za optimizaciju stranice. Rang web lokacija može se pratiti na Google tražilici i na servisu Alexa koji rangira web lokacije prema popularnosti. Korisnici mogu postavljati ciljeve i pratiti konverziju kroz aktivnosti posjetitelja (prijava korisnika, pretplata na novosti, kupnja...). GoingUp omogućuje analizu i prezentaciju trendova prometa na stranici prema povijesnim podacima. WebStats Live! usluga omogućuje različite predefinirane izvještaje sa podacima o prometu na stranici u realnom vremenu i ostalim informacijama. Alat ima jasne i razumljive grafikone, te vizualni prikaza korisnika prema lokacijama na mapi, a omogućuje i analizu web lokacije pomoću toplinskih mapa. Kontrolna ploča je prilagodljiva i nudi razne korisne widgete. Integracija s platformama kao što su Joomla, Blogger, WordPress, itd. omogućena je instaliranjem plugina. Korisničko sučelje je zanimljivo za korištenje, ne zahtjeva odličnu brzinu interneta kako bi se brojni elementi na stranici učitali. Za korisnike koji žele detaljnu analizu performansi stranice ovaj alat vjerojatno neće biti dovoljan, s obzirom da neke funkcionalnosti nedostaju, a postojeće nisu dovoljno robusne. Dodatno, ima nedostatak izvora za online učenje, a korisnička podrška moguća je putem chata na stranici proizvođača, te nema mobilnu aplikaciju.

3.3.12. Open Web Analytics

Ovo je alat koji dolazi u obliku besplatne PHP aplikacije koju korisnik instalira na server organizacije. Upravo u tome leži jedan od glavnih nedostataka; potrebno je kvalitetno tehničko i programersko znanje za instalaciju alata i prilagodbu i promjenu izvornog koda (Oberoi, 2015). Alat je razvijen kao odgovor zajednice na Google Analytics alat, te se mogu pronaći gotovo sve iste funkcionalnosti osim izvoza podataka, no zato nudi neke opcije koje GA nema. Podaci se prikupljaju metodom tagiranja stranica JavaScript kodom, a može se pratiti neograničen broj web stranica i pratiti do 5 prilagođenih varijabli. OWA prikuplja većinu osnovnih informacija o posjetiteljima (IP adresa, grad, država, operacijski sustav, IPS, preglednik, jezik preglednika), osnovne metrike, ulaznu i izlaznu stranicu, duljinu posjeta i vrijeme provedeno na stranici, interni i eksterni izvor prometa, nove posjetitelje, ponovne posjetitelje, stopu odustajanja, te povijest posjeta. Omogućuje praćenje događaja kao što su skidanja sadržaja, forme, pregled multimedije, RSS pretpate, Flash događaje. Dodatna funkcionalnost je što za svakog pojedinačnog nedavnog posjetitelja daje informacije kao što su lokacija, vrsta posjetitelja, pregledane stranice, dužinu posjeta, te izvor prometa. Ovaj alat pogodan je i za praćenje transakcija za e-trgovine umetanjem dodatnog koda. Alat nudi nekoliko korisnih analitičkih tehnika. Dostupna je segmentacija posjetitelja, filtriranje podataka, definiranje do 15 ciljeva, te praćenje njihova ostvarivanja putem konverzijskih lijevaka. Ima i opciju praćenja različitih aktivnosti korisnika na stranici, kao i praćenja uspješnosti marketinških kampanja, te doprinosu pojedinih kanala. Daje i izvještaje o ključnim riječima koje posjetitelji najčešće pretražuju, što se može iskoristiti za optimizaciju web stranice. Omogućuje podatke za analizu u realnom vremenu. Moguće je generirati izvještaje prema predefiniranim, ali i prilagođenim vremenskim razdobljima.

Za vizualizaciju izvještaja nudi uobičajene grafikone (dijagrami, tortni grafikoni), a omogućuje i vizualizaciju podrijetla posjetitelja na Google mapi. Dodatna prednost je što nudi i toplinske mape za klikove korisnika na stranici, te video prikaz kretanja miša posjetitelja (opcije koje nisu dostupne u GA). Kontrolna ploča omogućuje dodavanje bilo kojeg izvještaja na „live“ dashboard, dok samo korisničko sučelje podsjeća na starije verzije Google Analytics alata, no dosta je intuitivno za korištenje. Opcija izvoza podataka ne postoji unutar aplikacije odnosno na

korisničkom sučelju, stoga je moguće napraviti samo izvoz iz baze podataka. Alat dolazi sa ugrađenom podrškom za praćenje stranica koje koriste WordPress i MeidaWiki. Od nedostaka se još mogu izdvojiti nepostojanje mobilne aplikacije, te činjenica da se alat ne ažurira često jer se financira samo donacijama.

3.3.13. StatCounter

Alat koji je razvijen 1999. godine kao alat za praćenje web statistika, sa sjedištem u Irskoj. Nudi besplatnu verziju sa osnovnim funkcionalnostima ili plaćene verzije za tvrtke koje imaju više od 250000 pregleda mjesečno ili žele dodatne mogućnosti. Mnogi korisnici ocijenili su ovaj alat odličnim i jednostavnim za praćenje osnovnih statistika (Trust Radius, 2014). Korisnici mogu izraditi svoj besplatni račun i koriste uslugu u oblaku. Podaci se prikupljaju korištenjem log datoteka, ali se od korisnika zahtjeva da integriraju poseban kod na stranici kako bi se mogle prikupljati informacije o posjetiteljima. Glavna prednost ovakvog prikupljanja podataka je što se prate preglednici, a ne zahtjevi servera, te se tako dobiva uvid u stvarni broj posjetitelja koji je realističniji. Također, korisnici mogu odabrati da li žele vidljivo ili nevidljivo praćenje korisnika. Alat prati metrike na dvije razine. Prva razina su agregirane statistike o prometu na stranici: pregledi stranica, sesije, broj posjetitelja, novi posjetitelji (ove statistike mogu se pregledavati prema danu, mjesecu, godini ili specifičnim vremenskim razdobljima i grafički prikazati), stopa odustajanja, popularne stranice, ulazne i izlazne stranice, izlazni linkovi, izvori prometa, duljina posjeta, ponovni posjetitelji. Od događaja je dostupno samo praćenje skidanje sadržaja. Druga razina su informacije o posjetiteljima: IP adresa, grad, država, operacijski sustav, internet preglednik, rezolucija ekrana, omogućenost JavaScripta. Moguće je dodati opisne informacije o posjetiteljima kako bi se olakšalo njihovo praćenje. Dostupne su i posebne analize određenog broja posljednjih posjetitelja koje uključuju: put posjetitelja na stranici, nedavni pregledi stranica i aktivnosti posjetitelja na stranici, mapa podrijetla nedavnih posjetitelja.

Od analitičkih tehnologija za optimizaciju web stranice dostupna je analiza ključnih riječi koje posjetitelji upisuju u internet tražilice i analiza nedavnih ključnih riječi, te analiza plaćenog

prometa. Također se analizira i put posjetitelja na stranici, te internet preglednici koji generiraju najviše prometa. Dobiveni podaci mogu se filtrirati prema raznim kriterijima, a omogućen je i drill-down za pregled detalja u izvještajima. Još jedna zanimljiva funkcionalnost su dodavanje prilagođenih tagova za povezivanje prilagođenih podataka sa pregledom stranice, što omogućuje segmentiranje prometa na stranici. Za upite i izvještaje su dostupni povijesni podaci, ali i podaci u realnom vremenu. Vizualizacija izvještaj može se napraviti samo pomoću osnovnih dijagrama (linijski, stupčasti i sl.). Kontrolne ploče su prilagodljive i omogućen je izvoz sumarnih statistika u XLS ili CSV formatu. Ima plug-in za WordPress. StatCounter omogućuje korisnicima slanje tjednih i mjesečnih izvještaja e-mailom, a kod plaćenih verzija omogućuje slanje dnevnih izvještaja. Prednosti ovog alata su jednostavnost i intuitivnost u korištenju, te brzo generiranje velikih setova povijesnih podataka. Ipak alatu nedostaju neke kompleksne funkcionalnosti koje se mogu pronaći u drugim alatima, vizualizacije nisu atraktivnog izgleda, a prilagodbe trebaju obavljati napredni korisnici jer zahtijevaju dodavanje koda.

3.3.14. Adobe SiteCatalyst (Adobe Analytics)

Adobe je 2009. godine preuzeo tvrtku Omniture, a time i njihov alat SiteCatalyst koji postaje dio Adobe Marketing Cloud platforme koja uključuje nekoliko alata. Klijenti koji koriste ovaj alat najčešće su velika poduzeća, prije svega zbog njegove visoke cijene od nekoliko (i više) tisuća dolara mjesečno. Za razvoj i efektivno korištenje zahtijeva se dosta tehničkog znanja. Implementacija alata je visoko prilagođena određenom poduzeću i prikupljaju se točno određene metrike koje su potrebne za poslovanje. To rezultira time da korisnik može odabrati veliki broj prilagođenih varijabli; 75 vezanih za promet na stranici, 100 vezanih za praćenje događaja, te 75 varijabli za praćenje konverzije (Suryavanshi, 2016). Radi se o softveru kao usluzi u oblaku, a podaci se prikupljaju tagiranjem stranica pomoću JavaScript koda, te je omogućen i uvoz eksternih podataka. Alat je pogodan i za web analitiku poslovanja e-trgovina. Osim već spomenutih prilagođenih varijabli koje se mogu pratiti, ovaj alat prati širok raspon standardnih metrika i događaja. Osim temeljnih metrika, prate se metrike za opisivanje posjeta i opisivanje posjetitelja, te za opisivanje angažmana posjetitelja, kao i konverzijske metrike. Također prati i

veliki broj metrika namijenjenih e-trgovini: dodavanje proizvoda u košaricu, otvaranje košarice kroz dodavanje prvog proizvoda, uklanjanje proizvoda iz košarice, inicijalno otvaranje košarice, pregledi košarice, broj naplata, pregledavanje proizvoda i sl. Omogućuje i praćenje metrika vezanih za video sadržaje, te metrika na društvenim mrežama. Dostupna je kvalitetna analiza korisnika jer je moguće integrirati podatke sa raznih online i offline kanala, a prate se i korisni KPI-jevi kao što su lojalnost kupaca, informacije o kupnji i profili posjetitelja.

Dostupan je i veliki broj kvalitetnih analitičkih tehnika. Tehnike segmentiranja i klasteriranja omogućuje grupiranje korisnika prema bilo kojoj varijabli. Moguće je i filtriranje podataka u izvještajima. Dostupna je analiza korisničkog puta i konverzijskih lijevaka, te analiza doprinosa pojedinih marketinških kanala. Jednostavna integracija s alatom Adobe Target omogućuje opcije A/B testiranja i multivarijantne analize. Važna prednost ovog alata je robustan alat za izvještavanje, a posebice za provođenje ad hoc analize sa dostupnim neograničenim podacima o kupcima u realnom vremenu, te drill down analizom podataka. Uz to što su podaci dostupni u realnom vremenu, povijesni podaci spremaju se od početka korištenja alata. Alati omogućuje uobičajenu vizualizaciju izvještaja, ali i napredne funkcionalnosti vizualizacije kao što su grafički prikazi regresijske analize i analize trendova, stabla odlučivanja, 3D geografski prikazi i prikazi puta korisnika, istovremena usporedba više izvještaja na korisničkom sučelju. Korisničko sučelje za izvještaje vrlo je intuitivno i jednostavno za navigaciju, a izvještaji su vizualno atraktivni, te ih je lako dijeliti. Kontrolna ploča radi na principu „drag and drop“ i može se prilagoditi u širokom rasponu formata. Korisničke ploče i izvještaji mogu se dijeliti putem e-maila i mobilnih uređaja, a uz to ima i integraciju sa Excelom. Izvještaji se mogu i preuzeti u više formata. Iako postoji razvijena korisnička podrška, korisnici su imali problema sa brzinom njihovih odgovora. Kao nedostatak može se navesti i limitiranost podataka koji se prikazuju na kontrolnim pločama i to što nisu atraktivnog izgleda kao kod ostalih alata. (Trust Radius, 2014).

3.3.15. Chartbeat

Ovo je komercijalni alat sa početnom cijenom od oko 10 dolara mjesečno, te se nudi u obliku softvera kao usluge u oblaku. Cilj ovog alata je prije svega praćenje i prezentacija podataka u realnom vremenu, a podaci se prikupljaju metodom tagiranja stranica pomoću JavaScript koda. Najveća odlika ovog alata je u tome korisnik u svakom trenutku zna što posjetitelji rade jer se svakih 15 sekundi na server Chartbeata šalju informacije o aktivnostima posjetitelja, i to ne samo o prometu već i o tome što oni rade na stranici (npr. tipkaju, čitaju, pregledavaju stranicu do dna, itd.), a potom se ti podaci prezentiraju na kontrolnoj ploči u realnom vremenu. Kontrolna ploča je zanimljiva sa mnogo grafičkih prikaza metrika prometa i korisničkih aktivnosti na svim platformama (mobilnim uređajima, računalima, tabletima). Postoji nekoliko sekcija na kontrolnoj ploči. Sekcija Aktivni posjetitelji mjeri ukupan broj trenutnih posjetitelja (daje i usporedbe sa drugim danima), prosječno vrijeme koje korisnik provede na stranici, te postotak korisnika koji pregledaju više stranica u jednom posjetu. Sekcija Učestalost posjeta daje analizu posjetitelja prema učestalosti posjeta: novi, ponovni ili lojalni posjetitelji. U sekciji Platforme razdvajaju se posjetitelji prema uređaju i platformi s koje pristupaju stranici. Sekcija Najpopularnije stranice daje uvid u to na kojim su stranicama posjetitelji i što rade na njima. Stranice se mogu rangirati prema broju posjetitelja na pojedinom sadržaju i prema vremenu koje korisnici provode na stranici. Sekcija posjetitelji prema izvoru prometa prikazuje grafički prikaz udjela različitih izvora prometa (omogućen pregled današnjeg dana, proteklog tjedna i mjeseca). Također su zanimljive specifične sekcije dnevnog i tjednog pregleda najvažnijih metrika vezanih za posjetitelje i sadržaje na stranici. Ovaj alat omogućuje analizu korisničkog angažmana za video sadržaje, te ostale sadržaje na stranici, što se može iskoristiti za optimizaciju stranice. U realnom vremenu omogućeno je multivarijantno testiranje najpogodnijeg naslova za trenutne posjetitelje, te testiranje pozicioniranja sadržaja kako bi se odabrala najefektivnija pozicija. U analizama se mogu koristiti i povijesni podaci. Dostupne su i toplinske mape koje pokazuju geografsku popularnost stranice na mapi svijeta. Sekcija za izradu izvještaja omogućuje izradu i pretplatu na prilagođene izvještaje. Podatke je moguće filtrirati i grupirati, te odrediti metrike u izvještaju. Izrađeni izvještaji mogu se odmah skinuti u obliku CSV datoteke ili poslati na mail, te se može pretplatiti na izvještaje koji će se slati na mail dnevno, tjedno ili mjesečno. Omogućuje integraciju sa Slackom, Google AMP-om, Facebook Instantom. Kontrolna ploča omogućuje

prilagodbu na način da se mogu umetnuti specifične sekcije i podesiti prikaz samo određenih sekcija, a korisničko sučelje ima lijep dizajn. Može biti moćan alat za web magazine i portale s vijestima koji imaju mnogo prometa na stranici, jer daje uvid u pojedinačne statistike za najpopularnijih 20 stranica na web lokaciji. Također, ima i mobilnu aplikaciju. Mana ovog alata je što daje samo pregled trenutnih događanja na stranici, no povijesni podaci nisu previše detaljni, stoga se ne preporučuje korisnicima koji žele detaljne povijesne podatke i povijesne statistike (Oberoi, 2015).

3.3.16. GoSquared

Radi se o alatu istoimene kompanije osnovane 2006. godine koja se fokusirala na jednostavnost korištenja i dizajn softverskog proizvoda. Ciljna skupina klijenata su srednja i velika poduzeća. (Trust Radius, 2014). Radi se o SaaS rješenju koje dolazi u besplatnoj verziji sa ograničenim funkcionalnostima, a za dodatne funkcionalnosti i veće količine prometa plaća se mjesečni iznos prema planovima korištenja. Alat ima dodatni segment namijenjen praćenju i analizi podataka internet trgovina koji dolazi u plaćenim verzijama. Podaci se prikupljaju JavaScript tagiranjem stranica. Metrike prometa i ostali analitički podaci na stranici prikazuju se u realnom vremenu u sekciji Now, a prate se: broj jedinstvenih posjetitelja na stranici (daje se usporedba sa najvećom i najmanjom vrijednosti u posljednjih 7 dana), promet na stranici (današnji i povijesni), trenutni posjetitelji (podijeljeni u sekcije svi, ponovni i tagirani, te prikaz zemlje podrijetla, stranice na kojoj su aktivni, te stranice sa koje su došli), prosječno vrijeme na stranici i prosječna dubina posjeta, grafički prikaz lokacija posjetitelja, jezici posjetitelja, popularne stranice, izvori prometa prema vrsti, twitter objave prema tagovima, najbolje marketinške kampanje, broj posjetitelja prema pristupnim uređajima, operacijskim sustavima i preglednicima koje koriste. Jedinstvenost ovog alata kod praćenja prosječnog vremena na stranici je što ostali alati daju rezultate prema prosječnim podacima, dok ovaj alat daje precizne podatke korištenjem alata Pinging (Fernando, 2014). Sekcija Trends daje uvid u povijesne tjedne ili mjesečne podatke za ključne agregirane metrike (posjeti, posjetitelji, pregledi stranica, stopa odustajanja, prosječno vrijeme pregleda sadržaja, pregledane stranice po posjetu), te omogućuje predikciju ključnih metrika. U ovoj

sekciji dobiva se i uvid u broj pojedinih događaja na stranici na određeni dan, tjedno ili mjesečno. Moguće je i praćenje individualnih posjetitelja putem sekcije People, gdje se mogu kreirati profili za registrirane korisnike, te integrirati podaci iz drugih aplikacija. Tu se prikupljaju podaci o korisnicima sa društvenih mreža, povijest sesija korisnika i sl. Omogućena je pretraga korisnika i pregled cijele povijesti, te segmentacija posjetitelja prema „pametnim grupama“ i slanje prilagođenih oglasa e-mailom. Alat automatski dodaje posjetitelje u pojedine grupe kada njihove karakteristike zadovolje određenu grupu.

Korisnici mogu dobivati dnevne izvještaje sa metrikama prometa i usporedbama metrika na e-mail. Korisničko sučelje je vrlo intuitivno sa kontrolnim pločama koje prikazuju statistike u realnom vremenu, te imaju prilagodljive widgete. Omogućeno je slanje obavijesti unutar aplikacije ili mailom vezano za promet na stranici. Može se integrirati sa različitim alatima poput Google Tag manager, Zendesk, RSS, Twitter, alatima za komunikaciju, vizualizaciju, upravljanje e-mailovima i sl. Korisna funkcionalnost je Live chat sa korisnicima na stranici. Podaci iz trendova i e-trgovine mogu se eksportirati u CSV obliku, a omogućen je i izvoz putem API-ja. Najveći nedostatak je jednostavnost, odnosno nepostojanje naprednih funkcionalnosti poput analize konverzijskog lijevka (Trust Radius, 2014). Također je i nedostatak kada se dosegne mjesečni limit pogleda stranice, ne može se pristupiti podacima do sljedećeg mjeseca (Oberoi, 2015). Alat nema razvijenu mobilnu aplikaciju. Nudi i posebnu stranicu sa opsežnom dokumentacijom za pomoć korisnicima, ali bi dokumentaciju trebalo malo poboljšati.

3.3.17. AT Internet – Analytics Suite

Kompanija AT internet originalno je proizvela besplatni softver za web analitiku koji je još dostupan, no 2007. godine preorijentirala se na softver za velika poduzeća. Tako 2015. godine lansiraju novi SaaS softver za web analitiku sa brojnim funkcionalnostima ali i visokom cijenom, zbog čega je namijenjen prije svega velikim poduzećima. Imaju mnogobrojne klijente diljem svijeta, a posebice u Europi (s obzirom da se radi o francuskoj tvrtki). Podaci se prikupljaju tagiranjem stranica i to uz pomoć napredne tehnologija „Soft tagging“ koja omogućuje brzo i

jednostavno tagiranje. Nema uzorkovanja podataka što čini metrike i izvještaje vrlo pouzdanima. Ovo je opsežan alat koji uključuje analitiku na više uređaja (web, mobilni uređaji, intranet, aplikacije), te praćenje društvenih mreža u realnom vremenu. Uključuje analizu korisničkog angažmana na stranici, navigacije korisnika, prometa na stranici, izvora prometa prema kanalima, tehnologije, geografskog rasporeda korisnika, retencije korisnika, a mjeri i rušenje aplikacije. Prati se i korisnička interakcija sa oglasima koji sadrže video, audio i slične sadržaje. Omogućuje praćenje metrika specifičnih za internet trgovine kao što su: zarada po proizvodu, prosječna vrijednost košarice, učestalost kupnje pojedinog korisnika i slično. Također se mogu dodati i prilagođene metrike. Analytics Suite nudi napredne analitičke opcije. Podaci se u potpunosti mogu segmentirati i filtrirati, a omogućuje i A/B i multivarijantno testiranje, praćenje marketinških kampanja i njihove profitabilnosti, praćenje e-mail kampanja, definiranje i praćenje ciljeva. Ovaj alat ima i vlastitu specifičnu tehnologiju pod nazivom ClickZone koja omogućuje analizu pomoću toplinskih mapa i preklapanja. Kroz Data Query sekciju omogućeni su ad hoc upiti, te rudarenje velikih količina podataka. Mogućnosti analitičkog izvještavanja su napredne sa intuitivnim sučeljem koje omogućuje analizu više kategorija odjednom, a nudi i predefinirane analize podataka prilagođene različitim industrijama. Za izvještavanje su dostupni podaci u realnom vremenu. Korisničko sučelje alata je intuitivno, a kontrolne ploče u potpunosti su prilagodljive i mogu se izraditi prema posebnim potrebama korisnika, te su djeljive unutar poduzeća. Moguće je napraviti izvoz podataka iz svih izvještaja u XLS, PDF ili CSV obliku, te se može postaviti slanje izvještaja na dnevnoj, tjednoj ili mjesečnoj razini. Alat se može integrirati sa raznim drugim alatima kao što su: Power BI, Optimizely, MetrixLab, itd. Omogućuje izvoz velikih količina podataka i kompleksnih izvještaja u nekoliko minuta. Dodatna prednost je kvalitetna korisnička služba i podrška koja je vrlo stručna i brza u odgovaranju na upite. Ovaj alat nudi široki raspon vrlo kvalitetnih funkcionalnosti, ali je cijena najveći nedostatak.

3.3.18. FoxMetrics

Radi se o softveru tvrtke Rawsoft namijenjenom poduzećima svih veličina. Komercijalni je softver, a cijene se kreću od 20 do 120 dolara mjesečno, dok cijena enterprise verzije nije poznata javno (ITQlick, 2017). Ovo je SaaS rješenje, a podaci se prikupljaju JavaScript tagiranjem stranica. Foxmetrics omogućuje praćenje metrika sa bilo kojeg uređaja, te omogućuje praćenje prilagođenih metrika ovisno o potrebama poslovanja. Najvažnija odlika ovog alata je što pruža brojne informacije i metrike o prometu i korisnicima. Na kontrolnoj ploči prikazuju se podaci o trenutnim posjetiteljima (demografike, korisnička interakcija sa stranicom, ponovni i novi posjetitelji i sl.) u realnom vremenu. Osim toga prate se trendovi standardnih metrika prometa na stranici, razni događaji (instalacije aplikacije korisnika, pregled novosti i sl.), a u sekciji Profili automatski se grade korisnički profili i životni ciklus kupca sa raznim podacima kao što su: podaci o klikanju, otvaranje e-mailova, povijest kupnje, itd. Ovaj alat pogodan je za praćenje analitike e-trgovine jer nudi praćenje KPI-jeva i indikatora performansi vezanih za prodaju. U okviru analitičkih tehnologija omogućuje segmentiranje prometa stranice i filtriranje kupaca prema različitim karakteristikama, A/B testiranje, analizu konverzijskih lijevaka i aktivnosti posjetitelja nakon napuštanja lijevka, analize napuštanja košarice i napuštanja stranice, te analizu doprinosa marketinških kampanja prema konverzijama korisnika. Korisna funkcionalnost su i ankete za korisnike u kojima iskazuju svoja iskustva sa alatom, te analiza njihovih odgovora. Nad podacima se mogu provoditi ad hoc analize sa povijesnim podacima, te drill down podataka u realnom vremenu. Predefinirani izvještaji daju podatke u realnom vremenu, prateći KPI-jeve poput stope konverzije, zadržavanja posjetitelja i slično. Kontrolna ploča i predefinirani izvještaji vrlo su intuitivni i prilagodljivi, a kontrolna ploča sadrži i brojne korisne widgete. U sekciji Triggers omogućuje se dodjeljivanje automatskih reakcija određenim aktivnostima, primjerice kreiranje različitih grupa kupaca za slanje e-mailova i poruka ovisno o njihovim aktivnostima na stranici. Moguća je integracija sa mnogim platformama kao što su: Magento, Shopify, Adobe, Campaign Monitor i brojnim drugima. Svi izvještaji mogu se izvoziti u obliku CSV datoteka. Najveći nedostatak je što su važne funkcionalnosti (konverzijski lijevak, segmentacija) i potpuni pristup informacijama dostupni samo u najskupljoj enterprise verziji, no prednost je što cijena nije toliko visoka kao kod nekih drugih alata.

3.3.19. Adobe Digital Analytix

Do 2016. godine ovaj alat bio je vlasništvo tvrtke comScore, a potom ga preuzima tvrtka Adobe. Alat je dostupan u SaaS i on-premise verziji, a cijena ovisi o klijentu i njegovim specifičnim potrebama. Također, sama implementacija vrlo je fleksibilna i prilagođena pojedinim klijentima. Ova platforma kombinira kvalitetne demografike posjetitelja zajedno sa poslovnom analitikom, a pruža i uvid u ponašanje posjetitelja. Prednost je što se podaci spremaju na razini pojedinog korisnika u obliku sirovih podataka i mogu se izvoziti, a alat se može integrirati sa brojnim drugim aplikacijama. Moguć je i uvoz i integracija podataka iz postojećeg sustava korisnika. Izvještavanje i segmentacija omogućeni su u realnom vremenu, te je izvještavanje potpuno prilagodljivo. Na stranicama tvrtki Adobe i comScore nema informacija o funkcionalnostima ovog alata. Tvrtka Adobe u budućnosti će vjerojatno u potpunosti povući alat sa tržišta, te nastojati migrirati korisnike na Adobe Analytics platformu.

3.3.20. AWStats

Smatra se jednim od najboljih alata za web analitiku koji analizira log datoteke. Ovo je besplatni, open source alat koji se instalira na računalima korisnika u obliku desktop aplikacije. Sučelje se sastoji od samo jedne stranice koja je podijeljena u različite sekcije sa pregledom statističkih podataka. Uz informacije o posjetiteljima (IP adresa, grad, država, operacijski sustav, ISP, preglednik, rezolucija ekrana), prikuplja većinu važnih metrika kao što su: ulazne stranice, izlazne stranice, broj stranica po korisniku, jedinstveni posjetitelji, novi i ponovni posjetitelji, prosječno vrijeme provedeno na stranici i u sesiji, prosječan broj posjeta dnevno, mjesečno i godišnje, ukupni posjeti, najpopularnije stranice, izvori prometa, te eksterne ključne riječi. Omogućen je dnevni, mjesečni i godišnji pregled metrika i podataka, a informacije se ažuriraju na dnevnoj razini, ili u realnom vremenu ukoliko se preglednik osvježi (BlinkList, 2013). Jedinstveni posjetitelji broje se putem IP adresa, te se ujedno filtriraju posjeti (većine) robota, no ipak takvo mjerenje nije pouzdano jer se primjerice posjetitelj koji posjeti web lokaciju sa različitom IP adresom u isto vrijeme broji dva puta. Jedna od prednosti je što ima mogućnost

analize različitih log formata. Nedostatak je što ne prati aktivnosti korisnika kada se oni nalaze na stranici. Dodatno, veliki nedostatak je što ne omogućava dubinsku analizu podataka, odnosno nikakve napredne mogućnosti poput segmentacije, analizu konverzijskog lijevka, A/B testiranje i slično. Omogućuje zadovoljavajući broj osnovnih predefiniranih izvještaja, te vizualizaciju osnovnim dijagramima, dok za prilagodbu izvještaja omogućuje samo filtriranje i odabir mjesečnog ili godišnjeg perioda. Moguće je napraviti izvoz podataka iz izvještaja u XLS formatu. Nedostaci su i zastarjelo korisničko sučelje, te nepostojanje mobilne aplikacije. Može se reći da je ovaj alat namjenjen više tehnički potkovanim korisnicima, nego donositeljima strateških odluka temeljenih na ovakvim podacima.

4. KOMPARACIJA ALATA ZA WEB ANALITIKU

4.1. Višekriterijska analiza

Donošenje odluka prema višestrukim kriterijima (engl. Multiple Criteria decision making, MCDM) problem je donošenja odluka u uvjetima gdje postoji više od jednog kriterija odluke. Glavno obilježje višekriterijskog odlučivanja je da se koristi za rješavanje vrlo složenih i kompleksnih problema odlučivanja (Stepić, 2016). Stoga se u problemima višekriterijskog odlučivanja mogu pronaći određena obilježja (Vlah, 2008, Xu & Jang, 2001):

- postojanje više kriterija i podkriterija koji tvoje hijerarhiju
- kriteriji su obično konfliktni
- raznovrsnost kriterija (prema mjernim jedinicama, vrsti - kvantitativni ili kvalitativni, i sl.)
- postojanje velikog broja kriterija
- nesigurnost u odlučivanju zbog subjektivnosti ocjenjivača i nedostatka informacija ili pogrešnih informacija

Postoje dvije osnovne vrste višekriterijskih problema (Deluka-Tibljaš *et. al.*, 2013):

1. **Višeciljno odlučivanje** – koristi se za „dobro strukturirane probleme“, odnosno one problema kod kojih je poznato sadašnje stanje, ciljevi, te način postizanja ciljeva. Kod ovakvih problema broj rješenja je beskonačan (velik), karakterizira ga više funkcija cilja koristi se za pronalazak rješenja i izbor. Metode koje se mogu koristiti kod višeciljnog odlučivanja su: STEM metoda, parametarske metode, metoda zadovoljavanja ciljeva, itd.
2. **Višeatributivno odlučivanje ili višekriterijska analiza** – koristi se za „loše strukturirane“ probleme, gdje su ciljevi vrlo složeni, nejasno formulirani, postoje brojne neizvjesnosti. Kod ovakvih problema broj rješenja je određen (mali), a primjenjuju za evaluaciju i izbor već poznatih rješenja.

U ovom radu koristi se *višekriterijska analiza* upravo zbog toga što odluka o odabiru alata za web analitiku prema funkcionalnostima predstavlja složen i loše strukturiran problem, za čije će se rješavanje provesti evaluacija i izbor između unaprijed definiranih softvera. U ovoj odluci najčešće sudjeluje nekoliko stručnjaka u poduzeću koji predstavljaju različite interese. Osim toga zahtjevi tržišta i samog poduzeća podložni su promjenama, a novi softveri stalno se pojavljuju na tržištu, što čini ovaj problem još složenijim. Stoga je potrebno koristiti metodu koja će brzo i efikasno obraditi prikupljene podatke i u konačnici generirati optimalno rješenje.

Višekriterijska analiza se može definirati kao model donošenja odluka koji se sastoji od (Hajkowicz & Collins, 2007 navedeno u Deluka-Tibljaš *et. al.*, 2013) :

- skupa rješenja (varijanti koje treba rangirati ili razvrstati donositelj odluke),
- skupa kriterija (većinom višedimenzionalnih kriterija koji se stoga mogu vrednovati samo različitim mjernim jedinicama),
- vrijednosti (ocjena) svake varijante po svakom kriteriju

U višekriterijskoj analizi mogu se koristiti dvije vrste metoda (Xu & Jang, 2001):

1. **Nekompenzacijske metode**– ne dopuštaju pregovaranje s atributima. Tu se ubrajaju: maxmin metoda, maxmax metoda, konjuktivna i disjunktivna metoda i metoda dominacije i druge.
2. **Kompenzacijske metode** – dopuštaju pregovaranje s atributima, odnosno dopušta se popuštanje na kvaliteti jednog atributa ako se kompenzira poboljšanjem u jednom ili više

drugih atributa. Tu se ubrajaju: vagana metoda zbrajanja, AHP metoda, TOPSIS, suglasne metode, metoda evidentnog rezoniranja i druge.

U ovom radu za evaluaciju alternativa i izbor rješenja primijenjena je metoda Analitičkog hijerarhijskog procesa (AHP) koja će biti detaljnije pojašnjena.

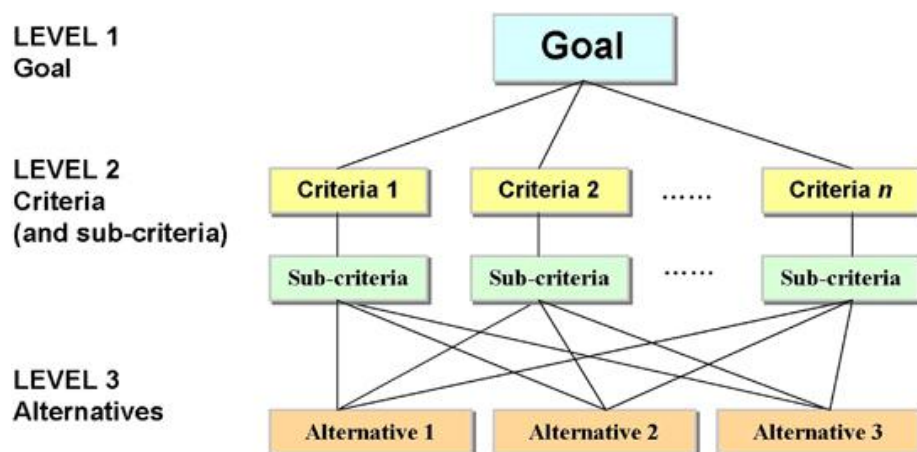
4.1.1. AHP metoda

Metodu Analitičkog hijerarhijskog procesa razvio je Thomas Saaty početkom sedamdesetih godina dvadesetog stoljeća, a ona predstavlja vrlo važnu metodu za odlučivanje koja ima svoju primjenu u rješavanju kompleksnih problema čije elemente čine ciljevi, kriteriji, podkriteriji i alternative (Begičević, 2008). Primjenom AHP metode ostvaruje se kvalitetna priprema za proces donošenja odluke kreiranjem hijerarhije problema. Zatim se vrši uspoređivanje u parovima elemenata hijerarhije (ciljeva, kriterija i alternativa) odozgo prema dolje ili u obrnutom smjeru čime se ostvaruje kontrola konzistentnosti procjena, te se na kraju vrši sinteza svih uspoređivanja i određuju se težinski koeficijenti za svaki element. Kompleksnost problema raste s brojem kriterija i s brojem alternativa. Dodatna odlika ove metode je što ona prati prirodan način djelovanja ljudskog uma kroz raščlanjivanje složenih problema na jednostavnije koji se grupiraju po određenoj logici međusobne sličnosti. AHP metoda u praksi se može primijeniti za probleme izbora, rangiranja, alokacije resursa, benchmarking i sl., stoga je ova metoda pronašla široku primjenu u brojnim područjima kao što su industrija, obrazovanje, menadžment, promet i drugi.

Proces donošenja odluka primjenom Analitičkog hijerarhijskog procesa može se opisati kroz nekoliko temeljnih koraka (Saaty, 2008):

- 1. Korak:** U prvom koraku potrebno je odrediti problem, te prikupiti relevantne podatke i potrebna saznanja

- 2. Korak:** Sastoji se od strukturiranja hijerarhije odlučivanja sa ciljem na vrhu, zatim kreiranjem središnjih razina na kojima se nalaze kriteriji i o njima zavisni podkriteriji, do najniže razine koju obično čini skup alternativa.



Slika 11: Hijerarhijska struktura AHP modela

Izvor: http://www.palgrave-journals.com/jba/journal/v4/n3/fig_tab/jba200834f4.html

- 3. Korak:** U trećem koraku potrebno je izraditi matrice usporedbe elemenata u parovima za svaku hijerarhijsku razinu. Svaki element na gornjoj razini koristi se kao temelj za usporedbu elemenata na prvoj razini ispod. Donositelj odluke određuje kojem kriteriju (alternativi) daje prednost ili obje predložene opcije smatra jednako bitnima. Preferencije donositelja odluke izražavaju se uz pomoć Saatyveve skale relativne važnosti koja ima 5 stupnjeva i 4 međustupnja verbalno opisanih intenziteta.

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važno	Dvije aktivnosti jednako doprinose cilju.
3	Umjereno važnije	Na temelju iskustva i procjena, daje se umjerena prednost jednoj aktivnosti u odnosu na drugu.
5	Strogo važnije	Na temelju iskustva i procjena, strogo se favorizira jedna aktivnost u odnosu na drugu.
7	Vrlo stroga, dokazana važnost	Jedna aktivnost izrazito se favorizira u odnosu na drugu, njezina dominacija dokazuje se u praksi.
9	Ekstremna važnost	Dokazi na temelju kojih se favorizira jedna aktivnost u odnosu na drugu, potvrđeni su s najvećom uvjerljivošću.
2,4,6,8	Međuvrijednosti	
1.1 – 1.9	Decimalne vrijednosti	Pri usporedbi aktivnosti koje su po važnosti blizu jedna drugoj, potrebne su decimalne vrijednosti kako bi se preciznije izrazila razlika u njihovoj važnosti.

Slika 12: Saaty-eva skala relativne važnosti

Izvor: Begićević, N. (2008). Višekriterijski modeli odlučivanja u strateškom planiranju uvođenja e-učenja

4. **Korak:** U ovom koraku se na temelju relativnih važnosti iz usporedbe elemenata pomoću matematičkog modela izračunavaju težine kriterija, podkriterija i alternativa, koje se zatim sintetiziraju u ukupne prioritete alternativa. Ukupni prioritet pojedine alternative izračunava se tako da se zbroje njezini lokalni prioriteti ponderirani s težinama elemenata više razine.
5. **Korak:** U petom koraku provodi se rangiranje i odabir alternative.

Postoje dva modela AHP metode:

1. **Relativni model** – radi se o tradicionalnom AHP modelu u kojem se alternative međusobno uspoređuju u parovima u odnosu na kriterije kako bi se utvrdili prioriteti.
2. **Model rejtinga**- u ovom modelu se za svaki kriterij (podkriterij) utvrđuju standardi, te se ocjenjuju alternative pojedinačno prema svakom kriteriju.

Razlika u ova dva modela očituje se u dijelu usporedbe alternativa, dok su ostali koraci identični. Osnovna prednost korištenja *rejting modela* je smanjenje broja potrebnih komparacija kada se radi o velikom broju alternativa, stoga se broj alternativa može povećavati a broj komparacija u modelu ostaje isti (Belderrain *et al.*, 2010). Upravo zbog velikog broja alternativa u ovom radu

koristiti će se rejting model, jer bi korištenjem tradicionalnog modela broj komparacija bio preko 1000 što je vremenski dugotrajno i iscrpljujuće.

Osnovne prednosti AHP metode su mogućnost prilagodbe donositelja odluke vezano za broj kriterija i alternativa o kojima se odlučuje i kreiranje hijerarhijske dekompozicije složenih modela. Ova metoda omogućuje integraciju kvalitativnih i kvantitativnih faktora odlučivanja, konstantno uspoređivanje parova elemenata koje smanjuje greške u procjeni, te efikasnost u grupnom donošenju odluka. Prednosti su i generiranje brzih i kvalitetnih rješenja, te programski alati za podršku u izvođenju metode. Unatoč brojnim prednostima i širokim mogućnostima primjene, ova metoda ima i neka ograničenja kao što su (Begičević, 2008):

- nedovoljno velika Saatyeva skala relativne važnosti
- postizanje prihvatljivog omjera konzistencije je često vrlo teško
- nisu dozvoljene neusporedive alternative
- najčešće je potrebno napraviti veliki broj komparacija u parovima

4.1.2. Kriteriji za evaluaciju alata za WA

Odluka o odabiru alata za WA kompleksna je zbog brojnih ranije navedenih područja koja je potrebno analizirati pri donošenju takve odluke. S obzirom da su funkcionalnosti alata najvažniji kriterij u odabiru alata, koji je uz to vrlo kompleksan, u usporedbi alata izostavljeni su ostali važni kriteriji poput cijene, hardverski i softverski zahtjevi alata i ostali. Kriteriji i podkriteriji za evaluaciju funkcionalnosti odabrani su na temelju pregleda relevantnih istraživanja na temu komparacije alata za web analitiku autora (Natakani i Chuang iz 2011., Creese & Veytsel iz 2000., Sharon iz 2011., Bothma & Fourie iz 2007.) i ostalih internetski izvori koji se bave komparacijom WA alata.

Kriterij Prikupljanje podataka – osnovni zadatak alata za WA upravo je prikupljanje podataka o posjetiteljima i događajima na stranici. Ovim kriterijem mjerit će se opširnost metrika prometa, podataka o posjetiteljima, događaja i ostalih podataka koje alat prati.

Kriterij Obrada i analiza podataka – svaki alat za web analitiku trebao bi imati određene mogućnosti obrade prikupljenih podataka kako bi se oni pretvorili u korisne informacije za korisnike.

- **Dostupne analitičke tehnologije** - dostupnost segmentacije, multivarijantne analize, A/B testiranja, SEO, upravljanja marketinškim kampanjama, analize puta korisnika, analize konverzijskog lijevka i ostalih analitičkih tehnologija, te kvaliteta tehnologija
- **Pravovremenost podataka** – dostupnost metrika i podataka za analizu u realnom vremenu
- **Mogućnosti analize podataka** – dostupnost povijesnih podataka za analizu i mogućnost izrade prilagođenih izvještaja

Kriterij Integracija podataka—odnosi se na mogućnost razmjene podataka (uvoza i izvoza) sa vanjskim sustavima, te integracije sa drugim alatima i plug-inima.

Kriterij Prezentacija informacija—odnosi se na mogućnosti prezentacije prikupljenih podataka putem kontrolnih ploča i izvještaja

- **Izgled i prilagodljivost kontrolne ploče**—mogućnosti prilagodbe, te izgled i intuitivnost kontrolnih ploča
- **Predefinirani izvještaji**— raznolikost predefiniranih izvještaja, te kvaliteta vizualizacija (osnovnih i naprednih poput toplinskih mapa, mapa klikova i sl.)

4.2. Super Decisions

Radi se o besplatnom, open-source softveru koji je razvio William Adams zajedno sa svojim timom od 1999. do 2003. godine, a najčešće se koristi u akademske svrhe. Razvoj alata financirala je organizacija *Creative Decisions Foundation* (osnovana od strane profesora T. Saatyja i njegove supruge) koja sponzorira edukaciju, istraživanja i razvoj softvera za napredne metode analitičkog donošenja odluka. Super Decisions koristi se za probleme donošenja odluka koji se temelje na zavisnosti i povratnim vezama između elemenata, a rješavaju se

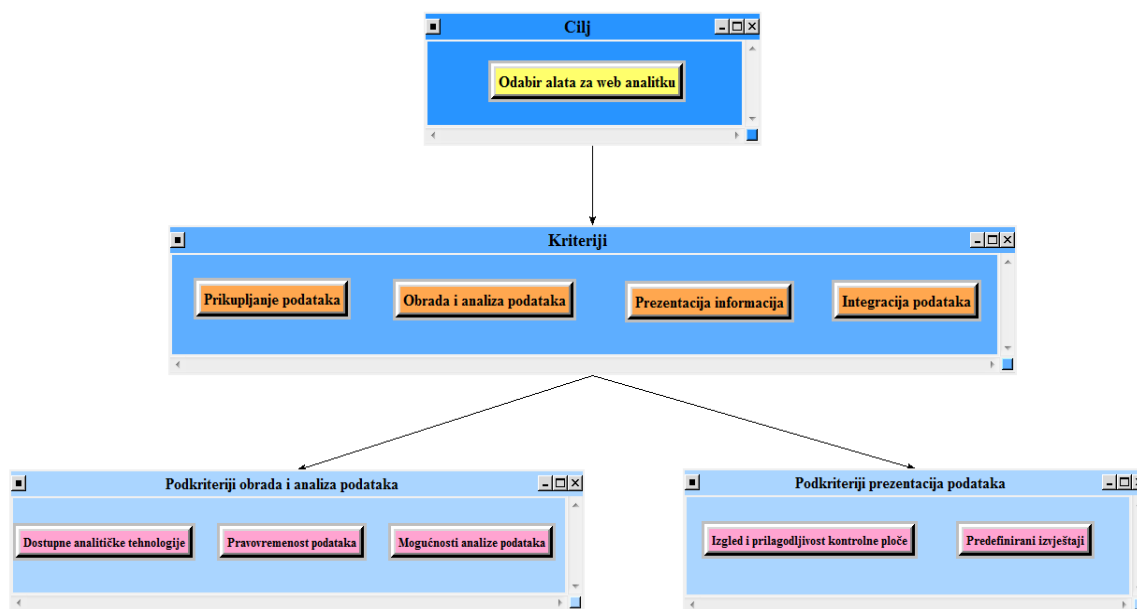
implementacijom Analitičkog hijerarhijskog procesa ili Analitičkog mrežnog procesa (ANP). Obje metode koriste isti proces prioritizacije koji se temelji na izvođenju prioriteta putem niza usporedbi parova elemenata ili izvođenjem prioriteta normalizacijom izravnih mjera (Super Decisions, 2013). U AHP metodi elementi odlučivanja postavljeni su u linearnu hijerarhiju od cilja na vrhu, preko kriterija do alternativa. Kod ANP metode ne mora nužno postojati cilj, već se modelira mreža međusobnih veza između elemenata, koja sadrži i povratne veze. Upravo iz tih razloga u ovom istraživanju koristi se AHP metoda s obzirom da postoji jasan cilj istraživanja i potrebno je uspostaviti linearnu hijerarhiju elemenata jer su kriteriji međusobno neovisni, kao i alternative.

Alat Super Decisions omogućuje provedbu metode AHP kroz sve prethodno navedene faze metode, a uz to omogućuje i provjeru *konzistentnosti* rezoniranja donositelja odluke i utvrđivanje ispravnosti rangova alternativa i težinskih vrijednosti kriterija i podkriterija. Provjera konzistentnosti važna je značajka u primjeni AHP metode. Ako se primjerice uzmu A, B i C kriterij, te ako je kriterij A važniji od B ($A > B$), a kriterij B važniji od kriterija C ($B > C$), onda automatski kriterij A mora biti važniji od kriterija C ($A > C$) kako bi odluka bila konzistentna. Stoga, opcija *Inconsistency* u alatui identifikira moguće greške i nekonzistentnost u procjeni pomoću pokazatelja nekonzistentnosti (engl. Inconsistency ratio) koji mora biti manji od 0.1 da bi se rezultati smatrali konzistentnima (Begičević, 2008). U okviru ovog alata model se gradi pomoću klastera sa elementima, a ne od elemenata u razinama. Tako najjednostavnija AHP hijerarhija sadrži klaster sa elementom cilja, zatim klaster sa elementima kriterija, te klaster sa elementima alternativa (Saaty, R., 2003). Ovaj alat odabran je zbog kvalitete i jednostavnosti u korištenju, te je uz to besplatan i podržava brojne verzije različitih operacijskih sustava. Podržava provođenje tradicionalne AHP metode, te AHP rejting model. Nedostatak alata je pomalo zastarjelo sučelje.

4.3. Provođenje AHP metode

Nakon što su analizirane teorijske postavke problema odabira alata za web analitiku, te provedena analiza svakog alata pojedinačno u prethodnim poglavljima, izrađena je hijerarhijska


struktura problema u programskom alatu Super Decisions 4.2. Slika 12. prikazuje hijerarhiju AHP modela rejtinga koja se sastoji od međusobno povezanih klastera cilja, kriterija i podkriterija sa pripadajućim članovima. U početnoj strukturi ovog modela alternative se izostavljaju(za razliku od tradicionalne AHP hijerarhijske strukture).



Slika 13: Hijerarhijska struktura problema s kriterijima i podkriterijima u alatu Super Decisions

Izvor: prikaz autora

U sljedećem koraku provodi se usporedba kriterija i podkriterija u parovima prema Saaty-evoj skali relativne važnosti. Prosudbe o prioritetima u ovom istraživanju donosi jedna osoba, odnosno istraživač na temelju teoretskih saznanja. Primijenjeno je uspoređivanje odozgo prema dolje, odnosno top down metodom. Usporedba elemenata u parovima može se vršiti opcijom *važnost* (engl. importance), *prioritetnost* (engl. preference) ili *sličnost* (engl. likelihood). Opcija importance se preporuča koristiti kod usporedbe objekata (kriterija i podkriterija), opcija preference kod usporedbe alternativa u odnosu na objekte i opcija likelihood kod scenarija i nesigurnih događaja, tipa analize rizika (Begičević, 2008). U ovom radu za usporedbu kriterija i podkriterija odabran je pristup usporedbe elemenata prema važnosti.

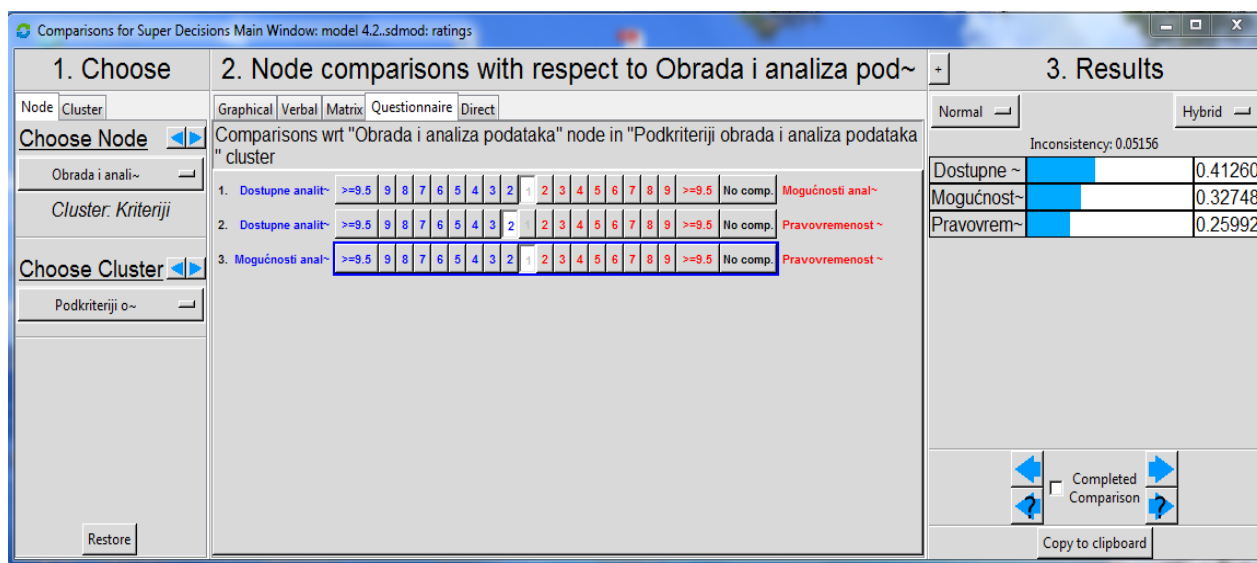


Slika 14: Usporedba kriterija u parovima

Izvor: prikaz autora

Na slici 13 prikazana je usporedba kriterija u parovima u obliku upitnika. Alat automatski izračunava težinske koeficijente kriterija na temelju odabranih vrijednosti intenziteta u usporedbama. Tako se može vidjeti da najveći prioritet ima kriterij „Obrada i analiza podataka“ od 0,439, zatim „Prikupljanje podataka“ od 0,294, potom „Prezentacija informacija“ sa koeficijentom 0,192, te kriterij „Integracija podataka“ sa najnižim prioritetom od 0,073. Također je automatski izračunat i koeficijent nekonzistentnosti koji iznosi 0,021 što je manje od 0,1, stoga je usporedba bila konzistentna. Super Decisions omogućuje nekoliko načina usporedbe elemenata: grafički, verbalno, matrično, u obliku upitnika, te unošenjem direktnih težinskih vrijednosti od strane korisnika.

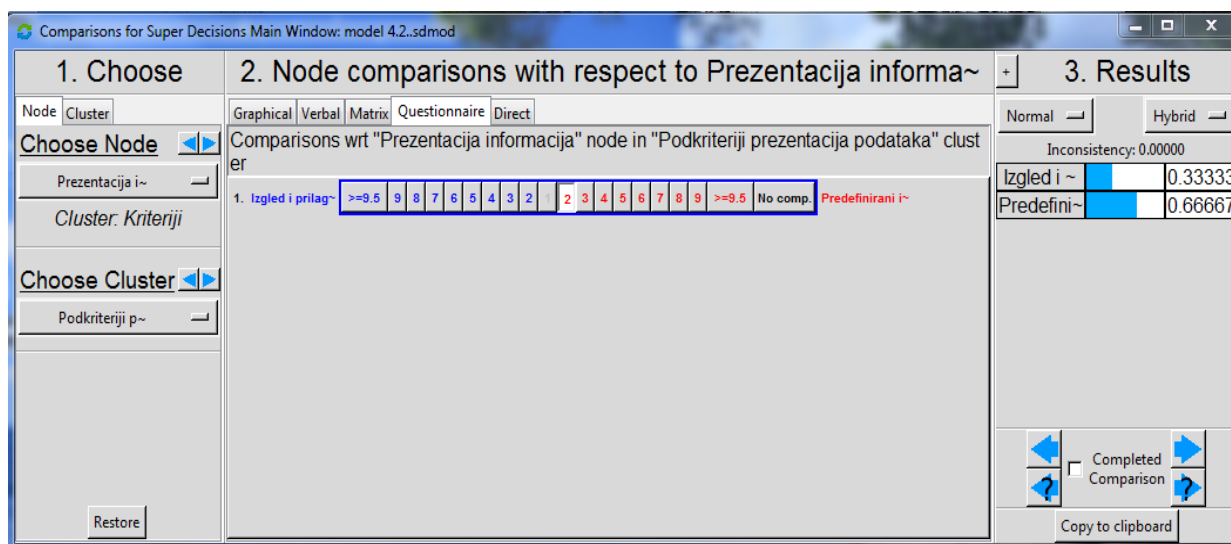
Nakon usporedbe kriterija potrebno je provesti i usporedbu važnosti podkriterija u odnosu na pripadajuće kriterije.



Slika 15: Usporedba podkriterija u odnosu na kriterij Obrada i analiza podataka

Izvor: prikaz autora

Na slici 14 prikazana je usporedba podkriterija zakriterij „Obrada i analiza podataka“, gdje težinski koeficijent za podkriterij „Dostupne analitičke tehnologije“ iznosi 0,412, za „Mogućnosti analize podataka“ iznosi 0,327, te za „Pravovremenost podataka“ iznosi 0,259. Ovi podkriteriji vrlo su bliski po važnosti stoga su razlike između koeficijenta male. Koeficijent nekonzistentnosti iznosi 0,051.




Slika 16: Usporedba podkriterija u odnosu na kriterij Prezentacija informacija

Izvor: prikaz autora

Na slici 16 može se vidjeti da je za kriterij „Prezentacija informacija“, podkriterij „Predefinirani izvještaji“ dobio veći koeficijent važnosti od 0,667 jer raznolikost predefiniranih izvještaja i dostupnost vizualizacija podataka ima veću važnost od „Izgleda i prilagodljivosti kontrolnih ploča“ koji su manje važan, ali ipak ne i nebitan podkriterij sa koeficijentom 0,333.

Nakon međusobne usporedbe kriterija i podkriterija ocjenjuju se alternative u odnosu na kriterije i podkriterije. Za svaki kriterij (podkriterij) potrebno je utvrditi kategorije standarda koje se moraju međusobno usporediti kako bi se dobili njihovi koeficijenti važnosti koje alat automatski idealizira (najbolja kategorija dobiva 1 a ostale su proporcionalno manje). Alternativama se dodjeljuje pripadajuća kategorija za svaki kriterij na temelju saznanja o kvalitetama funkcionalnosti koje imaju.

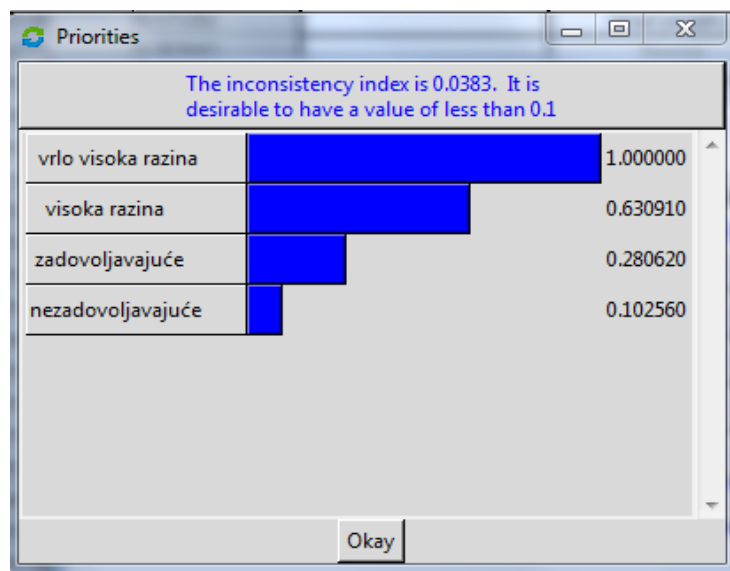
Izvršit će se usporedba alata za web analitiku koji su prethodno opisani u poglavlju 3.3. Izostavljen je alat Adobe Digital Analytix za kojeg nije pronađeno dovoljno informacija o funkcionalnostima, stoga se uspoređuje 19 alata od 20 analiziranih. Alternative se ocjenjuju pomoću opcije Desing → Ratings koji otvara tablični predložak za unos alternativa.



Slika 17: Težinski koeficijenti kategorija standarda kriterija „Prikupljanje podataka“

Izvor: prikaz autora


Kategorije standarda za podkriterij „Širina prikupljanja podataka“ su: izvrsna, iznad prosjeka, prosječna i ispod prosjeka. Kategorije se međusobno uspoređuju prema važnosti na isti način kao i kriteriji i podkriteriji. Alat automatski izračunava težinske kriterije, te idealizirane vrijednosti koje su prikazane na slici 17 zajedno sa koeficijentom nekonzistencije koji iznosi 0,047.



Slika 18: Težinski koeficijenti kategorija standarda podkriterija „Dostupne analitičke tehnologije“

Izvor: prikaz autora


Potom slijedi podkriterij „Dostupne analitičke tehnologije“ kojim se mjeri različitost, ali i kvaliteta analitičkih tehnologija alata, stoga su odabrane kategorije: vrlo visoka razina, visoka razina, zadovoljavajuće, nezadovoljavajuće. Idealizirane težinske vrijednosti prikazane su na slici 18, kao i koeficijent nekonzistencije koji iznosi 0,038.



Slika 19: Težinski koeficijenti kategorija standarda podkriterija „Pravovremenost podataka“

Izvor: prikaz autora

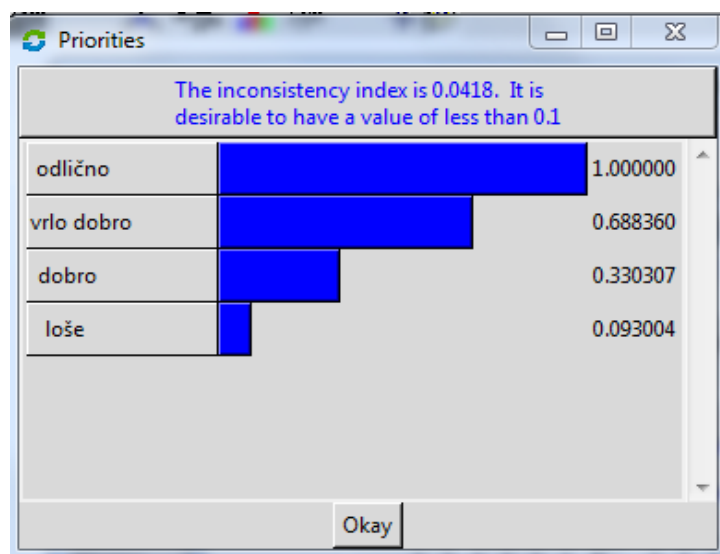
Za podkriterij „Pravovremenost podataka“ odabrane su kategorije standarda: potpuna i djelomična. Nakon što su međusobno uspoređene na slici 19 prikazani su težinski koeficijenti dobiveni izračunom alata.



Slika 20: Težinski koeficijenti kategorija standarda podkriterija „Mogućnosti analize podataka“

Izvor: prikaz autora

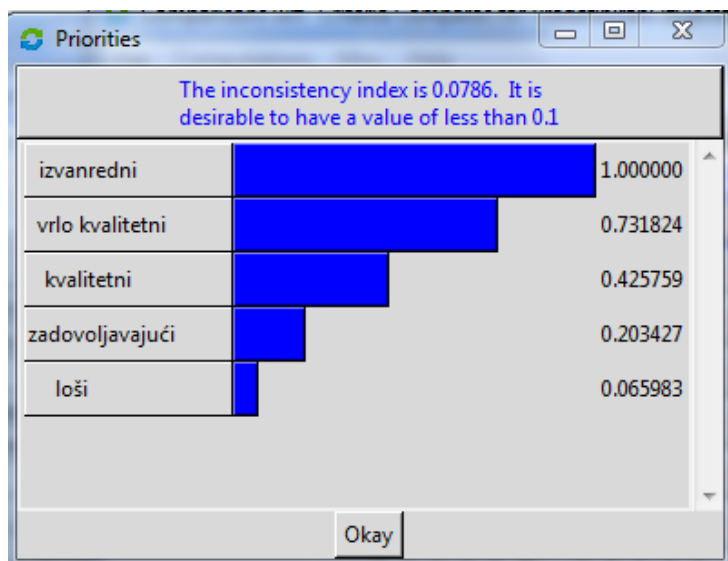
Slika 20 prikazuje težinske koeficijente za podkriterij „Mogućnosti analize podataka“ za pet kategorija standarda: izvanredne, vrlo kvalitetne, kvalitetne, zadovoljavajuće i loše. Odabrano je nešto više kategorija zbog većih oscilacija u kvaliteti prilagođenih izvještaja i dostupnosti povijesnih podataka. Koeficijent nekonzistentnosti iznosi 0,079.



Slika 21: Težinski koeficijenti kategorija standarda podkriterija „Izgled i prilagodljivost kontrolne ploče“

Izvor: prikaz autora


Za podkriterij „Izgled i prilagodljivost kontrolne ploče“ odabrane su četiri kategorije standarda: odlično, vrlo dobro, dobro i loše. Na slici 21 prikazani su težinski kriteriji dobiveni usporedbom kategorija, a koeficijent nekonzistentnosti iznosi 0,418.



Slika 22: Težinski koeficijenti kategorija standarda podkriterija „Predefinirani izvještaji“

Izvor: prikaz autora

Za podkriterij „Predefinirani izvještaji“ odabrane su iste kategorije standarda, te isti koeficijenti važnosti kao i za pokriterij „Mogućnosti analize podataka“. S obzirom na nešto veće razlike između alata u području predefiniranih izvještaja i vizualizacija odabrano je pet kategorija: izvanredni, vrlo kvalitetni, kvalitetni, zadovoljavajući i loši. Na slici 22 prikazuju se težinski koeficijenti i koeficijent nekonzistentnosti.



Slika 23: Težinski koeficijenti kategorija standarda kriterija „Integracija podataka“

Izvor: prikaz autor

Za zadnji kriterij „Integracija podataka“ koji jedini u analizi nije imao podkriterije, odabrano je također 5 kategorija standarda koje su iste kao kod prethodnog kriterija, no zbog različitih ocjena u usporedbi, dobiveni su različiti težinski koeficijenti prikazani na slici 23. Koeficijent nekonzistencije u ovom slučaju iznosi 0,025.

Super Decisions Ratings									
	Priorities	Totals	Dostupne analitičke tehnologije 0.181262	Pravovremenost podataka 0.114187	Mogućnosti analize podataka 0.143868	Izgled i prilagodljivost kontrolne 0.064157	Predefinirani izvještaji 0.128314	Integracija podataka 0.073814	Prikupljanje podataka 0.294398
Google Analytics	0.067342	0.821513	vrlo visoka razina	potpuna	vrlo kvalitetne	odlično	vrlo kvalitetni	vrlo kvalitetna	iznad prosjeka
Google Analytics 360	0.071505	0.872309	vrlo visoka razina	potpuna	izvanredne	odlično	vrlo kvalitetni	izvanredna	iznad prosjeka
Piwik	0.061857	0.754611	visoka razina	potpuna	vrlo kvalitetne	odlično	vrlo kvalitetni	vrlo kvalitetna	iznad prosjeka
IBM Digital Analytics	0.030678	0.374241	zadovoljavajuće	djelomična	zadovoljavajuće	dobro	kvalitetni	vrlo kvalitetna	prosječna
Webtrends Infinity	0.072667	0.896473	visoka razina	potpuna	izvanredne	odlično	vrlo kvalitetni	vrlo kvalitetna	izvršna
Mint	0.020435	0.249292	nezadovoljavajuće	potpuna	loše	vrlo dobro	loši	zadovoljavajuća	ispod prosjeka
Mixpanel	0.054611	0.666210	visoka razina	potpuna	kvalitetne	vrlo dobro	vrlo kvalitetni	kvalitetna	iznad prosjeka
KISSmetrics	0.055001	0.670971	visoka razina	potpuna	vrlo kvalitetne	vrlo dobro	kvalitetni	kvalitetna	iznad prosjeka
Woopra	0.051507	0.628340	visoka razina	potpuna	kvalitetne	dobro	kvalitetni	vrlo kvalitetna	iznad prosjeka
Clicky	0.065703	0.801519	vrlo visoka razina	potpuna	vrlo kvalitetne	vrlo dobro	vrlo kvalitetni	vrlo kvalitetna	iznad prosjeka
GoingUp	0.033655	0.410566	zadovoljavajuće	potpuna	zadovoljavajuće	vrlo dobro	kvalitetni	zadovoljavajuća	prosječna
Open Web Analytics	0.059454	0.725287	visoka razina	potpuna	vrlo kvalitetne	vrlo dobro	izvanredni	zadovoljavajuća	iznad prosjeka
StatCounter	0.037548	0.458057	zadovoljavajuće	potpuna	vrlo kvalitetne	vrlo dobro	zadovoljavajući	zadovoljavajuća	prosječna
Adobe Analytics	0.072687	0.886726	vrlo visoka razina	potpuna	izvanredne	vrlo dobro	izvanredni	izvanredna	iznad prosjeka
Chartbeat	0.046761	0.570441	nezadovoljavajuće	potpuna	kvalitetne	vrlo dobro	vrlo kvalitetni	kvalitetna	iznad prosjeka
GoSquared	0.059045	0.720303	nezadovoljavajuće	potpuna	kvalitetne	odlično	vrlo kvalitetni	izvanredna	izvršna
AT Internet - Analytics	0.073325	0.894505	vrlo visoka razina	potpuna	izvanredne	odlično	izvanredni	vrlo kvalitetna	iznad prosjeka
FoxMetrics	0.051392	0.626938	visoka razina	potpuna	kvalitetne	vrlo dobro	kvalitetni	kvalitetna	iznad prosjeka
AWStats	0.014828	0.180894	nezadovoljavajuće	djelomična	zadovoljavajuće	loše	zadovoljavajući	loša	ispod prosjeka

Slika 24: Ocjena svih alata prema kriterijima i podkriterijima


Izvor: prikaz autora

Nakon definiranja standarda za sve kriterije (podkriterije), svaka alternativa ocjenjena je prema pojedinom kriteriju ili podkriteriju. Kategorije standarda dodjeljivane su alatima na temelju funkcionalnosti koje posjeduju (a koje su opisane u ovom radu) i ocjena korisnika iz prakse na internetskim stranicama Trust Radius i G2 Crowd koje uspoređuju različite softvere.

4.4. Odabir alata za web analitiku

U posljednjem koraku radi se konačno rangiranje alternativa opcijom *sintetiziranja modela*, kojom alat izračunava idealizirane vrijednosti dijeljenjem svake normalizirane vrijednosti (umnožak prioriteta i totala svake alternative) sa najvećom od njih. Na slici 24 su prikazani


konačni rezultati dobiveni alatom Super Decisions, a na grafikonu 2 nalazi se grafički prikaz rezultata u alatu Excel.



Slika 25: Sintetizirani model sa prikazom prioriteta alternativa

Izvor: prikaz autora

U ovoj analizi najbolje rangirana alternativa je alat AT Internet - Analytics Suite, a slijede ga Adobe Analytics, Webtrends Infinity, Google Analytics 360 i ostali alati. Prva 3 alata imaju vrlo male razlike u rezultatima koji se nalaze u rasponu od 0,99-1, te se može zaključiti kako su među njima vrlo male razlike u kvaliteti funkcionalnosti. I četvrta alternativa, Google Analytics 360 rezultatom je blizu prvoj alternativni. Ovakvi rezultati ne iznenađuju s obzirom da se radi o četiri komercijalna alata, sa robusnim i kvalitetnim funkcionalnostima, namijenjenima prije svega velikim poduzećima. Najlošiji rezultat u analizi postigao je alat AWStats. Radi se o pomalo zastarjelom alatu čije su funkcionalnosti znatno lošije od onih koje nude moderniji alati. To se odnosi prije svega na manji raspon metrika i informacija koje prikuplja, te slabih mogućnosti obrade podataka.



Grafikon2:Prikaz rankinga alata

Izvor: prikaz autora

Osim generalne usporedbe alata neovisno o potrebama poduzeća, ova analiza i rezultati usporedbe mogu biti korisni u konkretnim situacijama odabira alata ovisno o različitim poslovnim modelima koji su kratko opisani u poglavlju 2.3.1. Primjerice, internet trgovine kojima je glavni zadatak ostvarenje prodaje trebale bi se fokusirati na rješenja koja nude napredne mogućnosti za e-trgovine kao što su: AT Internet, Adobe Analytics ili IBM Digital Analytics koji unatoč lošijim rezultatima može biti odličan alat za trgovačke modele. Ukoliko se radi o portalu sa vijestima (oglašivački model) preporuča se korištenje alata koji imaju fokus na statistike u realnom vremenu, te daju izvanredan prikaz onoga što korisnici rade na stranici u određenom trenutku. Takvi alati su GoSquared ili Chartbeat. Za trgovački, proizvođački i pretplatnički model korisni su alati Kissmetrics, Mixpanel i Woopra koji nude mogućnosti napredne analitike kupaca jer daju detaljan uvid u konverziju posjetitelja i izračun prihoda od posjetitelja.

5. ZAKLJUČAK

Sve više informacija i tehnologija korisnicima se nudi putem weba, stoga posljedično web lokacije poduzeća imaju sve dominantniju ulogu bez obzira na vrstu poslovanja. Masovne količine podataka koje se generiraju na web lokacijama kao rezultat korisničkih aktivnosti pružaju veliki potencijal za analizu i strateško korištenje takvih informacija u svrhu unaprjeđenja poslovanja. Upravo zbog ovih razloga značenje web analitike kroz vrijeme napredovalo je od pukog praćenja metrika, do ključne komponente poslovnog procesa uspješnih web stranica. Usporedno s tom činjenicom razvijalo se i tržište web analitike prateći trendove i nudeći sve veći broj naprednih softverskih rješenja za web analitiku. U posljednje vrijeme većina ovih alata objedinjuje brojne tehnologije koje omogućuju dubinske analize prikupljenih podataka, a čiji rezultati mogu biti od velike koristi za donositelje odluka.

Poduzeća koja žele ozbiljno konkurirati na suvremenom tržištu moraju kreirati i provoditi kvalitetnu organizacijsku strategiju web analitike kojom će biti utvrđeni svi zahtjevi za web analitikom, uključujući metrike, KPI-jeve, te potrebne analitičke tehnologije. Tek nakon ispunjenja ovog preduvjeta može se započeti analiza i odabir alata za web analitiku. Čak i ako su zahtjevi jasno definirani, odluka o odabiru alata za WA vrlo je kompleksna s obzirom na veliko i rastuće tržište softvera, te brojne kriterije o kojima je potrebno voditi računa. Osim uobičajenog kriterija cijene, vrlo važan kriterij su funkcionalnosti alata, potom tehnički aspekti, podrška dobavljača i ostala područja. Kriterij funkcionalnosti alata samostalno predstavlja kritično i kompleksno područje u kojem se proizvođači alata imaju priliku diferencirati. Bez sistematičnog modela ocjene alata, proces donošenja odluke o odabiru alata može biti neefikasan i neuspješan.

U ovom radu se kroz teoretski dio u svrhu razumijevanja problematike pobliže pojašnjavaju pojam, povijest i osnovne komponente web analitike, s naglaskom na njezinu svrhu i položaj u poslovanju. Zatim se govori o alatima za web analitiku, njihovim funkcionalnostima, razvoju i situaciji na tržištu, te se analizira dvadeset odabranih alata koji su dio aktivnog i raznolikog tržišta web analitike. Nakon upoznavanja značajki alata, njihovih prednosti i nedostataka, u posljednjem dijelu provodi se usporedba alata uzimajući u obzir isključivo njihove funkcionalnosti. U empirijskom istraživanju razvijen je AHP model za višekriterijsko

odlučivanje sa definiranim kriterijima i podkriterijima usporedbe, koji je omogućio sistematizaciju teorijskih saznanja i pripremu scenarija odlučivanja. Nakon izrade AHP hijerarhije, primjenom ostalih koraka metodologije uspoređeno je 19 alata o kojima je pronađeno dovoljno informacija, te je prihvaćena je hipoteza postavljena na početku rada:

H₁: Postoje razlike u razini kvalitete funkcionalnosti alata za web analitiku.

Istraživanjem je utvrđeno da alati imaju dostupne različite funkcionalnosti, te da iste funkcionalnosti koje posjeduju variraju u kvaliteti. Svi proizvođači nude softvere koji prate sve ili većinu standardnih metrika koje definira Web Analytics Association, na temelju kojih generiraju veći ili manji broj različitih izvještaja. Stoga da bi se dodatno diferencirali, proizvođači nude veliki raspon ostalih funkcionalnosti ili stavljaju naglasak na kvalitetu nekih posebnih funkcionalnosti.

Standard na koji većina korisnika pomisli kada se govori o web analitici je alat Google Analytics. Prema podacima servisa Datanyze za prosinac 2016. godine, besplatnu verziju ovog alata koristi oko 52 % korisnika, a zajedno sa komercijalnom verzijom Google Analytics 360, tvrtka Google zauzima 79 % tržišta web analitike. Ovakva popularnost nije slučajna jer Google Analytics zaista nudi široki spektar kvalitetnih funkcionalnosti za besplatan alat. Njegova komercijalna verzija u ovoj analizi nalazi se na 4. mjestu, odmah iza 3 velika proizvođača koja također nude komercijalne softvere: AT Internet, Adobe Analytics i Webtrends infinity. Odmah iza njih na 5. mjestu nalazi se besplatna verzija Google Analyticsa, a slijede ga Clicky, Piwik i Open Web Analytics za koje bi se moglo reći da su odlične alternative GA.

Iako su prva četiri softvera najbolji izbor za velika poduzeća kojima je potrebno više prilagođenih metrika, visoko prilagodljivi proizvod i robusne mogućnosti analize podataka i klijenata, alati pretrpani funkcionalnostima nisu idealno rješenje za sva poduzeća. Ovisno o veličini poduzeća i modelu poslovanja postoje razne potrebe za analizom web sjedišta, zbog čega je važno odabir alata uskladiti sa potrebama poduzeća. Mala, pa i srednja poduzeća mogu pronaći kvalitetna rješenja u besplatnim alatima i nadograđivati ih prema vlastitim potrebama.

Ako se primjerice radi o portalu sa vijestima, fokus se treba usmjeriti na alate koji imaju kvalitetan pregled statistika i korisničkog angažmana u realnom vremenu poput GoSquareda i Chartbeata, dok s druge strane e-trgovine trebaju izabrati alate koji imaju naglasak na metrike i funkcionalnosti za internet trgovine, kao što su AT Internet, Adobe Analytics i slično.

U ovoj analizi mogu se identificirati određena ograničenja koja obično karakteriziraju višekriterijske modele odlučivanja. Usporedba alata u istraživanju je rezultat preferencija istraživača na temelju teorijskih saznanja iz čega proizlaze dva najvažnija ograničenja. Prvo je subjektivnost ocjenjivača u dodjeljivanju važnosti kriterijima i podkriterijima, te određivanju rejtinga. Za povećanje eksterne validnosti ovog modela, sudionici ocjenjivačke grupe trebali bi biti zaposlenici različitih odjela poduzeća koji bi dali različite težine kriterijima ovisno o svom području poslovanja. Drugo ograničenje je rizik od nedostatka informacija ili pogrešnih informacija unatoč nastojanju da se prikupi što više literature o ovoj problematici i alatima za WA. Treće ograničenje vezano je za činjenicu da su kriteriji usporedbe vezani samo uz funkcionalnosti alata, dok su ostala područja poput cijene, tehničkih aspekata i druga, zanemarena zbog prevelike kompleksnosti modela i nedostatnih informacija.

Ovaj rad daje doprinos akademskoj literaturi na području web analitike, a posebno području analize i komparacije softvera za web analitiku, gdje postoji kronični nedostatak stručne literature. Također, može biti polazište za daljnja istraživanja ove problematike i nadogradnju predloženog modela za komparaciju alata članovima akademske zajednice i stručnjacima iz prakse.

LITERATURA:

1. Begičević, N. (2008): Višekriterijski modeli odlučivanja u strateškom planiranju uvođenja e-učenje, doktorska disertacija, Fakultet organizacije i informatike, Varaždin
2. Bekavac, I. (2014): Komparativna analiza alata za web analitiku i web metrike, diplomski rad, Ekonomski fakultet, Split.
3. Belderrain, M. C. N., Simoes da Silva, A. C., Pantoja, F. C. M. (2010): Prioritization of R&D projects in the aerospace sector: AHP method with ratings, *Journal of Aerospace Technology and Management*, 2 (3), str. 339 – 348.
4. Burby, J., Brown, A., WAA Standards Committee (2007). *Web Analytics Definitions – Version 4.0*, Web Analytics Association
5. Clifton, B.(2010). *Advanced Web Metrics with Google Analytics* (2nd ed.). Indiana: Wiley Publishing, Inc.
6. Creese, G., Veytsel, A. (2000). *Web Analytics: Translating Clicks into Business*. Boston: The Aberdeen Group, Inc.
7. Davenport, T., Cohen, D., Jacobson, A. (2005): *Competing on Analytics*, Working Knowledge Research Report, Babson Executive Education
8. Deluka-Tibljaš, A., Karleuša, B., Dragičević, N. (2013): Pregled primjene metoda višekriterijske analize pri donošenju odluka o prometnoj infrastrukturi, *Građevinar* 65 (7), str. 619 – 631.
9. Fourie, I., Bothma, T. (2007): Information seeking: an overview of web tracking and the criteria for tracking software, *Aslib Proceedings*, 59 (3), str. 264 – 284.
10. Hausmann, V. (2012): *Developing a Framework for Web Analytics*, Master Thesis, University of Koblenz-Landau, Germany
11. IBM (2015): *IBM Digital Analytics User's Guide*, IBM Corporation
12. Inan, H. (2002): *Measuring the Success of Your Website: A Customer Centric Approach to Website Measurement*
13. Jansen, B. J. (2009): *Understanding User – Web Interactions via Web Analytics*, Morgan & Claypool
14. Kaushik, A. (2007): *Web Analytics: An Hour a Day*. Indiana: Wiley Publishing, Inc

15. Kaushik, A. (2009). Web Analytics 2.0: The Art of Online Accountability and Science of Customer Centricity. Indiana: Wiley Publishing, Inc.
16. Klanac, J., Perkov, J., Krajnović, A. (2013): Primjena AHP i PROMETHEE metode na problem diverzifikacije, *Oeconomica Jadretina* 2/2013, str. 10-15
17. Lenzen, R. (2004): Customer Analytics: It's All About Behavior, *DM Review*
18. McFadden, C. (2005): Optimizing the Online Business Channel With Web Analytics.
19. Nakatani, K., Chuang, T.-T. (2011): A web analytics tool selection method: an analytical hierarchy process approach, *Internet Research*, 21(2), str. 171–186.
20. Omidvar, M. A., Mirabi, V. R., Shokry, N. (2011): Analyzing the impact of visitors on page views with Google Analytics, *International Journal of Web & Semantic Technology*, 2,(1), str. 14–32.
21. Peterson, E.T. (2004): Web Analytics Demystified: A Marketer's Guide to Understanding How Your Web Site Affects Your Business. Celilo Group Media and CafePress
22. Phippen, A., Sheppard, L., Furnell, S. (2004): A practical evaluation of Web analytics, *Internet Research*, 14 (4) str. 284 – 293
23. Saaty, R. (2003): Decision Making in Complex Environments, Super Decisions Software Tutorial, Creative Decisions Foundation
24. Saaty, T., L. (2008): Decision Making with the analytic hierarchy process, *Int. J. Services Sciences*, 1(1)
25. Sen, A., Dacin, A. P., Pattichis, C. (2006): Current trends in web data analysis, *Communication of the ACM*, 49 (11)
26. Stepić, D. (2016): Višekriterijska analiza varijanata rekonstrukcije raskrižja županijske ceste 5025 i ulice Marinići u Viškovu, diplomski rad, Fakultet prometnih znanosti, Zagreb
27. Tklalac-Verčić, A., Sinčić-Čorić, D., Pološki-Vokić, N. (2011): Priručnik za metodologiju istraživačkog rada u društvenim istraživanjima, Zagreb: MEP d.o.o.
28. Trust Radius (2013): The Buyer's Guide to Digital Analytics Software
29. Vlah, S. (2008): Modeli višekriterijskog odlučivanja i heuristike za njihovo rješavanje, magistarski rad, Ekonomski fakultet, Zagreb
30. Waisberg, D., Kaushik, A. (2009): Web Analytics 2.0: Empowering Customer Centricity, *SEMJ.org* 2, No. 2.

31. Web Analytics Association (2008): Web analytics definitions – Draft for Public Comment
32. Xu, L., Yang, J. (2001): Introduction to Multi-Criteria Decision Making and the Evidential Reasoning Approach, Working Paper No. 0106, Manchester School of Management, Manchester
33. Zelenika, R. (2000): Metodologija i tehnike izrade znanstvenog i stručnog djela, četvrto izdanje, Ekonomski fakultet, Rijeka

Izvori s interneta:

1. Akhtar, O. (2014): Despite competition from Adobe, Google Analytics is still the most widely used web analytics tool, Direct Marketing News, raspoloživo na: <http://www.dmnews.com/social-media/despite-competition-from-adobe-google-analytics-is-still-the-most-widely-used-web-analytics-tool/article/369604/>, [3.12.2016.]
2. Analytics Magazine: Report explores future of Web Analytics, raspoloživo na: <http://analytics-magazine.org/report-explores-future-of-web-analytics/>, [3.12.2016.]
3. Beal, V. (2008): What are Cookies and What Do Cookies Do?, Webopedia, raspoloživo na: http://www.webopedia.com/DidYouKnow/Internet/all_about_cookies.asp, [25.11.2016.]
4. BlinkList (2013): AWStats Review: Open Source Tracking for Your Site, raspoloživo na: <http://blinklist.com/reviews/awstats>, [18.1.2017.]
5. Bull, K. (2016): Comparing IBM Digital Analytics with Google Analytics, raspoloživo na: <http://websocialanalytics.blogspot.hr/2016/06/comparing-ibm-digital-analytics-with.html>, [21.12.2016.]
6. Charlie, A. (2011): Google Analytics Real Time Reporting – First Look, Silicon Beach Training, raspoloživo na: <https://www.siliconbeachtraining.co.uk/blog/google-analytics-real-time-reporting-first-look>, [14.12.2016.]
7. Clicktale: Eyetracking for everyone, raspoloživo na: <https://www.clicktale.com/academy/blog/eye-tracking-for-everyone/>, [15.11.2016]

8. Datanyze (2016): Analytics market share in the Datanyze Universe, raspoloživo na: <https://www.datanyze.com/market-share/Analytics/Datanyze%20Universe>, [2.12.2016.]
9. Demers, T. (2013): Guide To Analytics Software Platforms: 25 Analytics Tools Compared, raspoloživo na: <http://searchengineland.com/web-analytics-software-comparison-identifying-the-right-web-analytics-tools-for-your-business-149373>, [7.12.2016.]
10. Fernando, D. (2014): Web Analytics Tools: Analytical Tools Other Than Google Analytics, raspoloživo na: <https://www.woorank.com/en/blog/analytical-tools-other-than-google-analytics>, [8.1.2017.]
11. G2 Crowd: Best Digital Analytics Software, raspoloživo na: https://www.g2crowd.com/categories/digital-analytics?utf8=✓&order=top_shelf, [7.2.2017.]
12. Gartner IT Glossary (2014): Application Service Provider (ASP), raspoloživo na: <http://www.gartner.com/it-glossary/asp-application-service-provider>, [27.11.2016.]
13. ITQlick: Foxmetrics – Software review, raspoloživo na: <https://www.itqlick.com/foxmetrics>, [16.1.2017.]
14. Kholod, A. (2015): 8 Ecommerce Analytics Tools You Should Know About, raspoloživo na: <https://www.api2cart.com/blog/8-ecommerce-analytics-tools-know/>, [4.1.2017.]
15. Melaugh, S. (2011): Web Stats: Alternatives to Google Analytics, raspoloživo na: <http://activegrowth.com/web-stats-alternatives-to-google-analytics/#Piwik>, [23.12.2016.]
16. Micro Market Monitor: Global Web Analytics Market Research Report, raspoloživo na: <http://www.micromarketmonitor.com/market-report/web-analytics-reports-4497748592.html>, [3.12.2016.]
17. Oberoi, A. (2015): The Top 31 Best Web Analytics Tools / Google Analytics Alternative, raspoloživo na: <https://www.adpushup.com/blog/web-analytics-tools-google-analytics-alternatives/>, [6.12.2016.]
18. Online Behavior (2016): Funnel Analysis with Google Analytics Data in BigQuery, raspoloživo na: <http://online-behavior.com/analytics/funnel-analysis>, [23.11.2016.]
19. Rappa, M., Business models on the web, raspoloživo na: <http://digitalenterprise.org/models/models.html>, [25.11.2016.]

20. Sharon, S. (2011): Choosing the Best Web Analytic Tools for your Web Analytics Suite, raspoloživo na <http://blog.intlock.com/choosing-the-best-web-analytic-tools-for-your-web-analytics-suite/>, [28.11.2016.]
21. Super Decisions: About Super Decisions, raspoloživo na: <http://sdbeta.superdecisions.com/about/>, [5.2.2017.]
22. Suryavanshi, G. (2015): Google Analytics vs Adobe Analytics, raspoloživo na: <http://blog.thedigitalgroup.com/gajendras/2015/10/26/google-analytics-vs-adobe-analytics/>, [11.1.2017.]
23. Visconti, R. (2015): IBM Digital Analytics (Coremetrics): The Best Retail Analytics Platform Today, raspoloživo na: <http://www.verticalnerve.com/blog/ibm-digital-analytics-coremetrics-best-retail-analytics-platform-today>, [21.12.2016.]

POPIS SLIKA

Slika 1: Proces web analitike	15
Slika 2: Primjer izvještaja iz Analoga, verzija beta 0.9	16
Slika 3: Usporedba grafičkog prikaza paradigmi Web Analitika 1.0. i Web analitika 2.0.	19
Slika 4: Primjer funnel analize u alatu Google Analytics	26
Slika 5: Primjer Google Analytics izvještaja o ukupnom prometu na stranici s prikazom udjela plaćenog i neplaćenog prometa	27
Slika 6: Vizualizacija prikupljanja podataka pomoću log datoteka	30
Slika 7: Vizualizacija prikupljanja podataka tagiranjem stranica	31
Slika 8: Primjer funkcionalnosti praćenja klikova posjetitelja pomoću toplinske mape alata Clicktale	38
Slika 9: Postotak korištenje alata za Web analitiku u svijetu (prosinac, 2016.)	40
Slika 10: Primjer Google Analytics korisničke ploče sa podacima u realnom vremenu	42
Slika 11: Hijerarhijska struktura AHP modela	67
Slika 12: Saaty-eva skala relativne važnosti	68
Slika 13: Hijerarhijska struktura problema s kriterijima i podkriterijima u alatu Super Decisions.....	72
Slika 14: Usporedba kriterija u parovima	73
Slika 15: Usporedba podkriterija u odnosu na kriterij Obrada i analiza podataka	74
Slika 16: Usporedba podkriterija u odnosu na kriterij Presentacija informacija	74
Slika 17: Težinski koeficijenti kategorija standarda kriterija „Prikupljanje podataka“	75
Slika 18: Težinski koeficijenti kategorija standarda podkriterija „Dostupne analitičke tehnologije“	76
Slika 19: Težinski koeficijenti kategorija standarda podkriterija „Pravovremenost podataka“ ...	77
Slika 20: Težinski koeficijenti kategorija standarda podkriterija „Mogućnosti analize podataka“	77
Slika 21: Težinski koeficijenti kategorija standarda podkriterija „Izgled i prilagodljivost kontrolne ploče“	78
Slika 22: Težinski koeficijenti kategorija standarda podkriterija „Predefinirani izvještaji“	79

Slika 23: Težinski koeficijenti kategorija standarda kriterija „Integracija podataka“	79
Slika 24: Ocjena svih alata prema kriterijima i podkriterijima	80
Slika 25: Sintetizirani model sa prikazom prioriteta alternativa	81

POPIS TABLICA

Tablica 1: Prednosti i nedostaci dviju osnovnih tehnika prikupljanja podataka	32
---	----

POPIS GRAFIKONA

Grafikon 1: Kriteriji za evaluaciju alata za web analitiku	10
Grafikon 2: Prikaz rankinga alata	82

SAŽETAK

U suvremenom poslovanju web lokacije imaju sve veći značaj za poduzeća jer predstavljaju važan aspekt odnosa sa kupcima. Upotrebljivost i funkcionalnost web lokacija ne smije biti zanemarena ukoliko poduzeće želi uspješnu online komunikaciju i poslovanje. Upravo web analitika osigurava alate koji omogućuju praćenje i izvještavanje o korištenju web stranice od strane posjetitelja, te upotrebu tih informacija kako bi se optimizirala stranica u svrhu povećanja prodaje i lojalnosti klijenata. Odluka o odabiru alata za WA vrlo je kompleksna s obzirom na veliko i rastuće tržište softvera, te brojne kriterije o kojima je potrebno voditi računa. Za potrebe ovog rada provedena je analiza 20 alata za web analitiku na temelju teorijskih saznanja, a usporedba alata provedena je prema kriterijima funkcionalnosti, dok su ostali elementi odluke izolirani u ovom istraživanju. U softveru Super Decisions razvijen je AHP model za višekriterijsko odlučivanje sa definiranim kriterijima i podkriterijima usporedbe, koji je omogućio sistematizaciju teorijskih saznanja i pripremu scenarija odlučivanja. Primjenom koraka AHP metode izvršena je usporedba 19 alata o kojima je pronađeno dovoljno informacija, te je prihvaćena je hipoteza da postoje razlike u razini kvalitete funkcionalnosti alata za web analitiku. Istraživanjem je utvrđeno da alati imaju dostupne različite funkcionalnosti, te da iste funkcionalnosti koje posjeduju više ili manje variraju u kvaliteti. Ponuđači softvera nastoje se diferencirati ponudom što većeg broja različitih funkcionalnosti ili stavljaju naglasak na kvalitet nekih posebnih funkcionalnosti, kao što je primjerice detaljno praćenje korisničkog angažmana na stranici u realnom vremenu. U rezultatima usporedbe, prva tri mjesta zauzeli su komercijalni alati AT Internet - Analytics Suite, Adobe Analytics i Webtrends Infinity sa vrlo malim razlikama u rezultatima, odnosno vrlo malim razlikama u kvaliteti funkcionalnosti. Od besplatnih alata očekivano najbolje je rangiran alat Google Analytics. Ovisno o veličini poduzeća i modelu poslovanja postoje razne potrebe za analizom web sjedišta, zbog čega je važno odabir alata uskladiti sa potrebama poduzeća.

Ključne riječi: web analitika, alati za web analitiku, Super Decisions, AHP metoda.

SUMMARY

In modern business there is increasing significance of websites for companies because they represent an important aspect of customer relations. Usability and functionality of the websites should not be ignored if company wants to establish a successful online communication and business. Web analytics provides tools that allow tracking and reporting on the usage of the website by visitors, and use of this information to optimize the site in order to increase sales and customer loyalty. The decision on the selection of web analytics tool is very complex due to the large and growing market of software and a multiple criteria that need to be taken into account. For purposes of this study, an analysis of twenty tools for WA was conducted based on theoretical knowledge and tools comparison was carried out according to the criteria of functionality, while other elements of decision are isolated in this research. With use of Super Decisions software, AHP model for multiple criteria decision making was developed with defined criteria and sub-criteria of comparison, which allowed systematization of theoretical knowledge and preparation of decision-making scenarios. Comparison of nineteen tools of which enough information was found is done by applying the steps of AHP method and hypothesis is accepted that there are differences in the quality of functionalities of tools for web analytics. The study found that tools for WA have different features available and that the same features they possess vary more or less in terms of quality. Software vendors seek to differentiate either through offering more different functionalities or by emphasizing the quality of specific functionalities, such as detailed tracking of user engagement on site in real time. In the results of comparison, first three places were taken by commercial tools: AT Internet – Analytics Suite, Adobe Analytics and Webtrends Infinity with minor differences in the results, or in other words with very small differences in the quality of functionalities. Among free tools, as expected, best ranked tool is Google Analytics. Depending on the size of the company and business model, there are different needs for analysis of websites, which is why it's important to align selection of tool with the needs of company.

Key words: web analytics, web analytics tools, Super Decisions, AHP method.